

Milton Aluísio G. Araújo

**PREVISÃO DE DEMANDA DE ENERGIA ELÉTRICA
POR MEIO DE REDES NEURAIS ARTIFICIAIS**

Dissertação de Mestrado, apresentada ao Programa de Pós-Graduação em Administração da Universidade Federal do Rio Grande do Sul como requisito para a obtenção do título de Mestre em Administração.

Orientador: Prof. Dr. João Luiz Becker.

Porto Alegre

2005

Dados Internacionais de Catalogação na Publicação (CIP)

A663p Araújo, Milton Aluísio Gamboa

Previsão de demanda de energia elétrica por meio de redes neurais artificiais / Milton Aluísio Gamboa Araújo
110 f. : il.

Dissertação (Mestrado) – Universidade Federal do Rio Grande do Sul, Escola de Administração, Programa de Pós-Graduação em Administração, Porto Alegre, 2005.

Orientador: Prof. Dr. João Luiz Becker.

1. Redes neurais artificiais. 2. Modelo de Predição. 3. Sistemas de informação. I. Título.

CDU 681.3

Bibliotecária responsável: Ana Maria Mattos – CRB10/930.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ADMINISTRAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO

Milton Aluísio G. Araújo

PREVISÃO DE DEMANDA DE ENERGIA ELÉTRICA
POR MEIO DE REDES NEURAIIS ARTIFICIAIS

Porto Alegre

2005

Milton Aluísio G. Araújo

**SISTEMA DE APOIO À DECISÃO PARA A PREVISÃO DE DEMANDA DE
ENERGIA ELÉTRICA POR MEIO DE REDES NEURAIS ARTIFICIAIS**

**Dissertação de Mestrado, apresentada ao Programa de
Pós-Graduação em Administração da Universidade
Federal do Rio Grande do Sul como requisito para a
obtenção do título de Mestre em Administração.**

Conceito final:

Aprovado em ____ de setembro de 2005.

BANCA EXAMINADORA

Prof. Dr. Antônio Carlos Gastaud Maçada – Universidade Federal do Rio Grande do Sul

Prof. Dr. Eduardo Ribas dos Santos – Universidade Federal do Rio Grande do Sul

Prof. Dr. Romeu Reginatto – Universidade Federal do Rio Grande do Sul

Orientador: Prof. Dr. João Luiz Becker – Universidade Federal do Rio Grande do Sul

Dedico este trabalho, com todo o meu amor e carinho à minha esposa, Júlia, e à minha filha, Laís, pela paciência que tiveram e pelas privações de convívio familiar que lhes impus durante todo o processo de pesquisa e elaboração do mesmo.

Igualmente o dedico aos meus pais, Glenir Teresinha Gamboa Araújo (*in memorian*) e Luis Araújo, pelas lições de vida, pelo incentivo aos estudos e, sobretudo, por terem me transmitido os verdadeiros valores da vida: caráter, honestidade, humildade e respeito ao próximo.

AGRADECIMENTOS

Esta talvez seja a parte mais difícil do presente trabalho, devido à imensa gama de contribuições e colaborações que recebi durante esta jornada, pois temo cometer omissões imperdoáveis. Mas vale tentar; desde já manifestando minhas sinceras desculpas aqueles que eu possa ter deixado sem o devido reconhecimento.

Em primeiro lugar, agradeço ao meu orientador, Prof. João Luiz Becker, Ph.D., pelos ensinamentos que foram muito além dos acadêmicos – com as disciplinas de Métodos Estatísticos e Pesquisa Operacional II, e das aulas adicionais sobre Redes Neurais – com lições de perseverança, humildade e fé, dispondo de seu escasso tempo para me atender nos momentos de aflição diante das inúmeras dificuldades que surgiram, sempre com sugestões precisas e, em nenhum momento, deixando de me colocar de volta ao caminho certo, quando eu me sentia perdido.

A todos os Professores do Grupo de Estudos em Sistemas de Informação e de Apoio à Decisão (GESID), bem como aos demais Professores do Programa de Pós-Graduação em Administração (PPGA), pela ajuda no decorrer das Disciplinas e dos trabalhos executados durante o curso.

À Escola de Administração da Universidade Federal do Rio Grande do Sul, de um modo geral, representada por todas as pessoas que ajudam a manter toda a infra-estrutura necessária ao ensino e à pesquisa, sempre contribuindo para manter o PPGA como um dos melhores cursos de Pós-Graduação do Brasil.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq pelo financiamento total deste estudo.

Aos colegas do PPGA, que sempre estiveram dispostos a dar apoio mútuo, para que todos pudéssemos cumprir nossa jornada.

À doutoranda do PPGA/GESID Marta Von Ende, pelas primeiras lições no mundo das redes neurais.

Ao colega do PPGA/GESID Luis Felipe Feldens pelo auxílio nas pesquisas.

Ao colega do tempo da graduação em Engenharia Elétrica e grande amigo, hoje Doutorando pela USP – São Carlos, Alessandro Goedtel pelo valeroso auxílio e dicas no desenvolvimento das redes neurais, sem os quais este estudo não teria sido finalizado dentro do prazo.

Aos meus familiares e amigos de um modo geral, por todo o incentivo durante a condução deste trabalho.

“A vida não é um corredor reto e tranqüilo que nós percorremos livres e sem empecilhos, mas um labirinto de passagens, pelas quais nós devemos procurar nosso caminho, perdidos e confusos, de vez em quando presos em um beco sem saída. Porém, se tivermos fé, uma porta sempre será aberta para nós. Não talvez aquela sobre a qual nós mesmos nunca pensamos, mas aquela que definitivamente se revelará boa para nós.”

A. J. Cronin.

RESUMO

Este estudo propõe um método alternativo para a previsão de demanda de energia elétrica, através do desenvolvimento de um modelo de estimação baseado em redes neurais artificiais. Tal método ainda é pouco usado na estimativa de demanda de energia elétrica, mas tem se mostrado promissor na resolução de problemas que envolvem sistemas de potência. Aqui são destacados os principais fatores que devem pautar a modelagem de um sistema baseada em redes neurais artificiais, que são: seleção das variáveis de entrada; quantidade de variáveis; arquitetura da rede; treinamento; previsão da saída. O modelo ora apresentado foi desenvolvido a partir de uma amostra de 125 municípios do Estado do Rio Grande do Sul (Brasil), nos anos de 1999 a 2002. Como variáveis de entrada, foram selecionados a temperatura ambiente (média e desvio-padrão anual), a umidade relativa do ar (média e desvio-padrão anual), o PIB anual e a população anual de cada município incluído na amostra. Para validar a proposta apresentada, são mostrados resultados baseados nas simulações com o modelo proposto.

Palavras-chave: Redes neurais artificiais. Modelo de predição. Energia elétrica.

ABSTRACT

This study proposes an alternative method to predict the electrical energy demand based in artificial neural networks. This method is not extensively used in electrical energy demand estimation despite the promising results in solving electrical power systems problems. It is highlighted the importance of the input variables, the design of the net and the training set for consistent results in estimating the output: the demand of electrical power. The samples were collected in 125 cities of Rio Grande do Sul (the southernmost State in Brazil), between 1999 and 2002. The variables used in this work are: the temperature (and its respective standard deviation), the air humidity (and its respective standard deviation), the GIP and the population in each city of the sample data. Simulation results are presented to validate the proposed approach.

Key words: Artificial neural networks. Forecasting model. Electrical power.

LISTA DE ILUSTRAÇÕES

Figura 1 – Distribuição setorial da demanda de energia elétrica no Brasil em 2003.	18
Figura 2 – Neurônio biológico.	26
Figura 3 – Potencial de ação de um neurônio	26
Figura 4 – Neurônio de Mcculloch e Pitts	27
Figura 5- Modelo de um neurônio (aperfeiçoado).	28
Figura 6 – Transformação afim produzida pela presença de um <i>bias</i>	30
Quadro 1 – Principais funções de ativação do neurônio artificial	31
Figura 7 – Exemplo de arquitetura de uma RNA.....	33
Figura 8 – Representação do modelo não-linear de um neurônio inserido em camadas de uma rede neural.....	34
Figura 9 – Aprendizado supervisionado	38
Figura 10 – Ilustração das direções de dois fluxos de sinal básicos em um perceptron de múltiplas camadas: a propagação para frente de sinais funcionais e a retropropagação de sinais de erro.	39
Figura 11 (a) – Esquema de estimação comparativo regressão \times RNA.....	48
Figura 11 (b) – Esquema para testes da RNA.....	48
Figura 12 – Perceptron de múltiplas camadas com duas camadas ocultas	50
Figura 13 – Estimativa de demanda residencial.	62
Figura 14 – Estimativa de demanda comercial.	63
Figura 15 – Estimativa de demanda industrial.	63
Gráfico 1 – Demanda residencial.	74
Gráfico 2 – Demanda comercial.	74
Gráfico 3 – Demanda industrial.	75
Figura 16 – Estimativa de demanda residencial – Região Centro-Oeste.....	77
Figura 17 – Estimativa de demanda comercial – Região Centro-Oeste.....	78
Figura 18 – Estimativa de demanda industrial – Região Centro-Oeste.....	78
Figura 19 – Estimativa de demanda residencial – Região Litoral e Sudoeste.....	80
Figura 20 – Estimativa de demanda comercial – Região Litoral e Sudoeste.....	80
Figura 21 – Estimativa de demanda industrial – Região Litoral e Sudoeste.....	81
Figura 22 – Estimativa de demanda residencial – Região Norte.....	82
Figura 23 – Estimativa de demanda comercial – Região Norte.	83
Figura 24 – Estimativa de demanda industrial – Região Norte.	83

LISTA DE TABELAS

Tabela 1 – Coeficientes e níveis de significância do modelo regressional.....	54
Tabela 2 – Coeficientes e níveis de significância do modelo regressional.....	54
Tabela 3 – Comparação entre os modelos.....	61
Tabela 4 – Comparação entre os modelos.....	61
Tabela 5 – Efeitos da retirada da variável temperatura e do seu respectivo desvio padrão do vetor de entrada da rede neural.	65
Tabela 6 – Efeitos da retirada da variável umidade relativa do ar e do seu respectivo desvio padrão do vetor de entrada da rede neural.	65
Tabela 7 – Efeitos da retirada da variável pib do vetor de entrada da rede neural.....	66
Tabela 8 – Efeitos da retirada da variável população do vetor de entrada da rede neural.	67
Tabela 9 – Variações topológicas da rede.....	68
Tabela 10 – Exemplo da metodologia utilizada para construir as amostras aleatorizadas.....	71
Tabela 11 – DPRS e variações percentuais em relação à rede padrão de cada uma das 30 amostras aleatorizadas.....	73
Tabela 12 – DPRS para a Região Centro-Oeste	77
Tabela 13 – DPRS para a Região Sul, Litoral e Porto Alegre	79
Tabela 14 – DPRS para a Região Norte.....	82
Tabela 15 – Comparação entre o modelo regionalizado e a rede padrão.....	84

LISTA DE ABREVIATURAS E SIGLAS

ARIMA – *Auto Regressive Integrated Moving Average* (modelo auto-regressivo integrado de predição de médias móveis)

DISME – Distrito Meteorológico

DPR – Desvio Padrão Residual

ELETROBRAS – Centrais Elétricas Brasileiras

EQM – Erro Quadrado Médio

FEE – Fundação de Economia e Estatística do Estado do Rio Grande do Sul

INMET – Instituto de Meteorologia

MATLAB – *Matrix Laboratory* (software de ferramentas matemáticas e matriciais)

MME – Ministério de Minas e Energia

PIB – Produto Interno Bruto

RNA – Redes Neurais Artificiais

S/PIB – Modelo de rede neural artificial processado sem a variável PIB

S/POP – Modelo de rede neural artificial processado sem a variável população

S/TEMP – Modelo de rede neural artificial processado sem a variável temperatura

S/URA – Modelo de rede neural artificial processado sem a variável umidade relativa do ar

SPSS – *Statistical Package for Social Sciences* (software de ferramentas estatísticas)

SUMÁRIO

1	INTRODUÇÃO.....	14
1.1	QUESTÃO DE PESQUISA.....	17
1.2	OBJETIVO GERAL.....	17
1.3	OBJETIVOS ESPECÍFICOS	17
1.4	CONTEXTO DE APLICAÇÃO.....	17
1.5	MOTIVAÇÃO E RELEVÂNCIA DO ESTUDO	19
1.6	ORGANIZAÇÃO DO TRABALHO	19
2	REVISÃO BIBLIOGRÁFICA	21
2.1	REDES NEURAIS ARTIFICIAIS – FUNDAMENTAÇÃO TEÓRICA	22
2.1.1	Neurônio biológico	25
2.1.2	Neurônio artificial.....	27
2.1.3	Arquitetura de redes neurais artificiais.....	32
2.1.4	Perceptron de múltiplas camadas	36
2.1.5	Aprendizagem de redes neurais artificiais	37
2.1.6	Algoritmo de treinamento	39
3	METODOLOGIA	44
3.1	VARIÁVEIS SELECIONADAS.....	46
3.2	BASE DE DADOS.....	47
3.3	ESQUEMA GERAL PROPOSTO	48
3.4	MODELOS UTILIZADOS NESTE ESTUDO	48
3.4.1	Modelo I.....	49
3.4.2	Modelo II	50
4	APRESENTAÇÃO E ANÁLISE DOS RESULTADOS	52
4.1	RNA <i>VERSUS</i> REGRESSÃO	52
4.1.1	Regressão linear multivariada	53
4.1.2	Rede neural artificial.....	54
4.1.3	Comparação entre os modelos	60
4.2	TESTES DE VARIÁVEIS DE ENTRADA.....	64
4.2.1	Modelo RNA – S/TEMP.....	64
4.2.2	Modelo RNA – S/URA.....	65

4.2.3 Modelo RNA – S/PIB	66
4.2.4 Modelo RNA – S/POP	66
4.3 VARIAÇÕES TOPOLÓGICAS NA REDE	67
4.4 ALEATORIZAÇÃO NOS DADOS DE ENTRADA	71
4.5 REGIONALIZAÇÃO DO MODELO (RNA)	76
4.5.1 Região Centro-Oeste	76
4.5.2 Região Sul, Litoral e Porto Alegre	77
4.5.3 Região Norte	80
4.5.4 Comparação entre a regionalização e o modelo padrão de rede neural	83
5 CONCLUSÕES E ESTUDOS FUTUROS	86
REFERÊNCIAS	89
ANEXO I – METODOLOGIA	94
ANEXO II – MAPA CLIMATOLÓGICO	96
ANEXO III – BASE DE DADOS	97

1 INTRODUÇÃO

Uma das principais metas do planejamento, segundo Audy e Brodbeck (2003), é diminuir o impacto das incertezas relacionadas ao futuro de qualquer organização. Prever o futuro passou a ser o foco da empresa moderna, através do estudo do comportamento de um conjunto de variáveis e da consequente ação para alcançar determinados objetivos com a máxima eficiência possível. Como a tarefa de prever o futuro, a partir de sistemas reais já implementados, seria onerosa para a organização, partiu-se para estudos baseados em modelos (suas características e propriedades), visto que tais modelos proporcionariam um melhor controle dos experimentos, ao invés de testes de campo em sistemas reais.

A busca de métodos, baseados em modelos, para a previsão de curto, médio e longo prazo, passou a despertar especial interesse, tanto de gestores quanto de pesquisadores nas mais diversas áreas, tais como economia, marketing, finanças e engenharia. Os modelos tradicionais de previsão – baseados em ferramentas matemáticas e estatísticas – ainda hoje são amplamente usados. Entretanto, devido ao acelerado avanço tecnológico observado nas duas últimas décadas, as pesquisas passaram a ser direcionadas para o uso de ferramentas mais modernas (e talvez mais eficientes) para desempenhar a tarefa de fazer previsões. Ainda que, a partir de 1987, tenham sido publicados vários artigos utilizando metodologias mais avançadas (por exemplo, algoritmos genéticos, lógica difusa e redes neurais) em modelos de previsão, tais modelos têm, em sua maioria, se concentrado na área econômica (HOBBS *et al.*, 1998; BJORGAN *et al.*, 2000), como a previsão em bolsas de valores, em séries econômicas e na previsão de preços de petróleo (ZANDONADE, 1993).

Segundo Shin *et al.* (2002), os modelos de apoio à decisão baseados em otimização representam o verdadeiro estado da arte para o futuro dos sistemas de informação. Tais modelos são divididos em três estágios básicos: (a) formulação; (b) solução; e (c) análise. A **formulação** se refere à geração do modelo em si, de forma que este se torne aceitável para a solução do problema. O estágio da **solução** se refere ao algoritmo utilizado para a solução do problema proposto. Já o estágio da **análise** diz respeito ao “*what-if*” da análise e suas interpretações do modelo para um conjunto de soluções.

Ainda para Shin *et al.* (2002), a maior tendência para as próximas décadas está centrada em um grande crescimento da meta-heurística para a solução de problemas estocásticos empregando técnicas como algoritmos genéticos, lógica difusa, modelagem probabilística, redes neurais, entre outros, tanto isoladamente quanto através dos chamados modelos híbridos (ABRAHAM; NATH, 2001; SANDAK; TANAKA, 2003), combinando duas ou mais das técnicas supracitadas.

Um dos setores que desperta especial interesse de governantes, gestores e pesquisadores, no que diz respeito à previsão de demanda, é o de energia elétrica. Isto é decorrente de suas características intrínsecas: uma vez produzida, ela deve ser distribuída e consumida, pois não pode ser armazenada. Assim, é necessário que se obtenha um perfeito equilíbrio entre demanda e oferta. A pesquisa de novos métodos de previsão de demanda de energia elétrica tem sido o alvo de estudos de pesquisadores e de planejadores da área de sistemas de energia, pelo acelerado crescimento da carga. É justamente na ponta do consumo que reside o primeiro passo no planejamento para a expansão do sistema (geração, transmissão e distribuição de energia elétrica). Deste modo, vários pesquisadores têm mostrado uma maior inclinação por modelos mais eficientes para a análise e a previsão de demanda de energia (HOBBS *et al.*, 1998; KERMANSHAHI, 1998; BOLZERN; FRONZA, 1986).

Apenas mais recentemente foi que o Brasil começou a dar seus primeiros passos em direção a modelos que utilizem tecnologia mais avançada para a previsão da demanda de energia elétrica (LORENTZ, 1995; SOTO; 1999; FLORES, 2000). Até o presente momento, o que se vê são modelos tradicionais – baseados em séries temporais – sendo utilizados na previsão de demanda de energia elétrica (BRANCO, 1986; SCHUCH, 1988; SPOSITO; 1991; GONZALEZ, 1991; SANTOS, 1996; ALVES, 1997; CAETANO, 1997; CAIO, 1998, entre outros).

No trabalho de Carpinteiro e Reis (2004), para a estimativa de demanda de energia elétrica, foi proposto o uso de redes auto-organizáveis em um modelo de estrutura hierárquica. Os autores mencionam que o processo de demanda é um processo complexo que são necessárias previsões cada vez mais precisas. A relação entre a carga e seus fatores exógenos tem caráter complexo e não-linear, o que torna estas previsões difíceis de serem modeladas através de técnicas convencionais, tais como as séries temporais e a regressão linear (CARPINTEIRO; REIS, 2004).

As variações de demanda no setor elétrico geralmente apresentam um quadro em constantes mudanças, típico de um processo estocástico, revelando uma certa fragilidade dos modelos paramétricos. Isto, por sua vez, torna as previsões destes modelos pouco confiáveis para o planejamento a médio e longo prazos, em setores como, por exemplo, o do Plano de Recuperação Setorial – PRS e o dos trabalhos de ciclo anual do Grupo Coordenador de Planejamento do Sistema Elétrico – GCPS, com o conseqüente comprometimento dos citados ciclos anuais de planejamento (BRASIL. MINISTÉRIO DE MINAS E ENERGIA. ELETROBRAS, 1999).

Buscar eficiência em um cenário com tantas variações é tarefa extremamente árdua, considerando-se as contingências apresentadas pelo Brasil, cuja dimensão continental deve exigir grande flexibilidade de critérios de ordem econômica, financeira, empresarial, ambiental e outros, que sempre ocorrem ao longo do tempo. O “Novo Modelo para o Setor Elétrico Nacional”, apresentado pelo presente governo, em 11 de dezembro de 2003 (BRASIL, 2003), que trata das novas regras para o setor elétrico, traz como foco principal a criação de condições para a retomada dos investimentos na expansão do sistema. Este trabalho focalizará, em sua essência, dois pontos do “Novo Modelo para o Setor Elétrico Nacional”, acima descrito, quais sejam:

- a) a reestruturação do planejamento de médio e longo prazos;
- b) o monitoramento, no curto prazo, das condições de atendimento.

Visualizando-se o quadro já apresentado, destaca-se a eficiência de modelos de previsão, no que diz respeito à sua maior precisão, criando, deste modo, um cenário mais seguro aos gestores responsáveis pela tomada de decisão. O propósito deste estudo é avaliar se os modelos mais modernos (em particular aqueles baseados em redes neurais artificiais) são superiores, em eficiência, aos tradicionais, que se norteiam por técnicas estatísticas, ou seja, modelos paramétricos obtidos por regressão estatística em séries temporais.

1.1 QUESTÃO DE PESQUISA

Existem vantagens na utilização de um modelo de previsão de demanda de energia elétrica baseado em redes neurais artificiais em relação ao uso dos modelos paramétricos tradicionalmente utilizados?

1.2 OBJETIVO GERAL

Desenvolver um modelo de previsão de demanda de energia elétrica baseado em redes neurais artificiais, comparando-o com um modelo paramétrico tradicional.

1.3 OBJETIVOS ESPECÍFICOS

Esta monografia tem como objetivos específicos:

- a) buscar, na revisão bibliográfica, diferentes tipos de variáveis de entrada (inputs) adequadas à consecução do modelo de previsão de demanda mais apropriado;
- b) treinar e validar as topologias de redes neurais escolhidas por meio de dados históricos;
- c) comparar os modelos baseados em redes neurais com modelos paramétricos tradicionais;
- d) testar variações nas topologias das redes neurais artificiais e verificar possíveis efeitos destas variações sobre a previsão da demanda de energia elétrica.

1.4 CONTEXTO DE APLICAÇÃO

No Setor Elétrico Nacional, a cada dois ou três anos, a Centrais Elétricas Brasileiras S.A., (ELETROBRAS) lança o Plano Nacional de Energia Elétrica para os próximos 10 a 20 anos. Tais planos, em geral, são baseados em modelos paramétricos com o uso de séries temporais, do tipo Box-Jenkins (*Auto Regressive Integrated Moving Average – ARIMA*) e simulações de processos estocásticos. Por exemplo, segundo o Relatório Geral – Plano 2015 (BRASIL. MINISTÉRIO DE MINAS E ENERGIA ELETROBRAS, 1994), tenta-se, redirecionar o planejamento para a análise e investigação de possíveis cenários de desenvolvimento, procurando privilegiar, em suas recomendações, aspectos conceituais e estratégicos que sejam vitais para a correta orientação do desenvolvimento do Setor Elétrico Nacional. Tais atualizações visam programar obras, prever mercado e projeções financeiras, adequação de programas e de recursos bastante escassos, que são atividades a serem exigidas e executadas no âmbito dos planos a curto e médio prazos.

Os cinco principais setores que demandam energia elétrica no Brasil são: industrial, comercial, residencial, público e rural. O Balanço Energético Nacional, referente ao ano de 2003 revela um quadro conforme ilustrado na Figura 1 (BRASIL. MINISTÉRIO DE MINAS E ENERGIA, 2004),

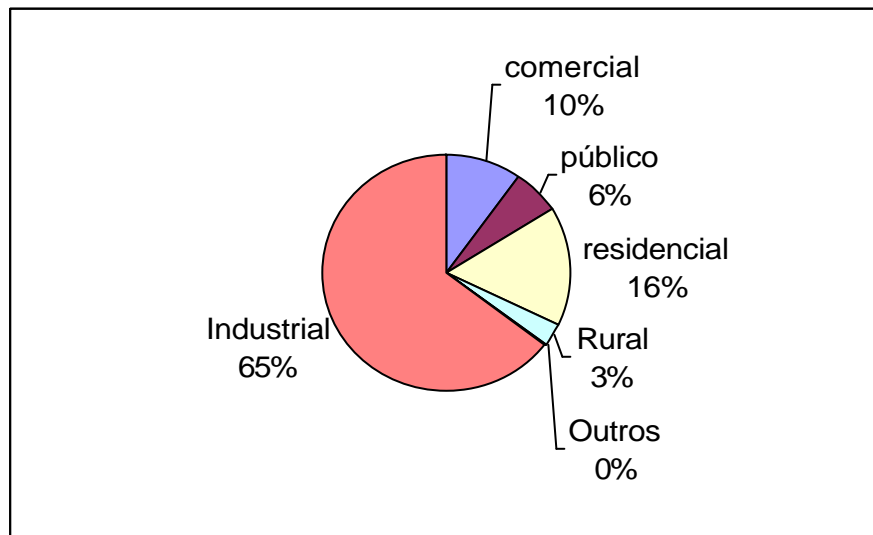


Figura 1 – Distribuição setorial da demanda de energia elétrica no Brasil em 2003.

Fonte: BRASIL. MINISTÉRIO DE MINAS E ENERGIA (2004).

O presente estudo pretende se concentrar nos três principais setores, que são o residencial, o comercial e o industrial, visto que os mesmos são atualmente responsáveis por 91% de toda a demanda de energia elétrica no Brasil.

1.5 JUSTIFICATIVA DO ESTUDO

Levando-se em conta o atual cenário da conjuntura econômica do Brasil, o atendimento da demanda de energia elétrica se constitui em um aspecto primordial para as projeções do crescimento econômico nacional. O planejamento eficaz de oferta de energia vai muito além da conservação de energia. Esta constatação pode ser feita a partir de uma comparação entre a parcela do crescimento do mercado que pode ser atendida através de ações de eficiência energética, que é muito pequena, com a oferta adicional que se faz necessária para o crescimento industrial. Este último, por sua vez, é a verdadeira mola-mestra do crescimento econômico do País e é igualmente o responsável pela maior parte da demanda da energia gerada. O *gap* entre a demanda e a oferta tem sido o verdadeiro responsável pelo compasso de espera em que se encontra o quadro econômico do Brasil.

Recorrendo-se novamente a Shin *et al.* (2002) e também a Courtney (2001), a maior tendência para as próximas décadas está centrada em um grande crescimento da meta-heurística para a solução de problemas estocásticos. Esta observação traz, para este estudo, uma justificativa bastante palpável no que diz respeito ao uso de uma técnica como a de redes neurais artificiais para a previsão eficaz de demanda de energia elétrica. Estas técnicas, com o propósito de agregar maior precisão a estas previsões, auxiliam os decisores a implementar ações cada vez mais eficazes no planejamento das alternativas para o atendimento mais rápido desta demanda e favorecendo o crescimento econômico do País.

1.6 ORGANIZAÇÃO DO TRABALHO

Este trabalho está assim organizado: no Capítulo 2 está a Revisão Bibliográfica, com especial ênfase na fundamentação teórica de redes neurais. No Capítulo 3 se encontra a

Metodologia, com as etapas utilizadas para a construção das redes neurais, as variáveis utilizadas para o seu equacionamento, o treinamento, testes comparativos com modelos tradicionais e ainda os próprios modelos utilizados no presente estudo. O Capítulo 4 traz os resultados obtidos através de simulações empregando o modelo proposto e suas respectivas análises. Por fim, o Capítulo 5 contém as conclusões e indicações para estudos futuros.

2 REVISÃO BIBLIOGRÁFICA

Segundo Crainer (2000), há uma unanimidade relacionada com o novo mundo da administração, que considera o processo decisório como parte vital no trabalho do gerente. A preocupação é tornar as decisões dos gerentes cada vez mais eficazes. Surgem, muito freqüentemente, pacotes de software que tentam transformar o processo decisório em uma fórmula, pois conforme Crainer (2000) de acordo com uma pesquisa realizada em 1996 pela Reuters, com 1200 gerentes, revelou que 43% deles acreditavam que o fato de receberem um volume excessivo de informações atrasa e afeta a capacidade de tomar decisões importantes. Por outro lado, tais pacotes não tomam a decisão em si, uma vez que, freqüentemente, a solução apontada por um software pode não conduzir o decisor à resposta correta. A realidade é que os gerentes tomam suas decisões baseados em uma combinação de intuição, experiência e análise. Como é impossível medir, de forma racional, tanto a intuição quanto a experiência, os gerentes caem na tentação de focalizar o lado analítico do processo decisório, a ciência em lugar da “misteriosa arte de tomar decisões“. Segundo Ribeiro, Rodrigues e Zaraté, (2003), estes fatores sugerem que, cada vez mais, os gerentes precisam de técnicas, modelos ou análises que lhes permitam tomar decisões mais rápidas, baseadas em informações mais precisas.

Conforme Carlsson e Turban (2002), os sistemas inteligentes passam a dominar o cenário, com um incremento considerável de pesquisas sobre lógica difusa (*fuzzy logic*), algoritmos genéticos (*genetic algorithms*), modelagem probabilística (*probabilistic modeling*), e, logicamente, o foco principal deste estudo: as redes neurais artificiais (*artificial neural nets*), consideradas pelos citados autores como áreas promissoras para o desenvolvimento dos sistemas de apoio à decisão (do inglês *Decision Support Systems – DSS*).

O *data mining*, ou mineração de dados, pode ser considerada como uma parte do processo de Descoberta de Conhecimento em Banco de Dados – DCBD (do inglês *Knowledge Discovery in Databases – KDD*). Segundo Goebel e Gruenwald (1999), o termo *KDD* é usado para representar o processo de converter dados de baixo nível em conhecimento de alto nível, enquanto que a expressão “mineração de dados“ pode ser definida como a extração de padrões ou modelos de dados observados. A mineração de dados combina métodos e

ferramentas das seguintes áreas: aprendizagem de máquina, estatística, banco de dados, sistemas especialistas e visualização de dados (CRATOCHVIL, 1999). Em outras palavras, a mineração de dados é a exploração e a análise, por meio automático ou semi-automático, de grandes quantidades de dados, com as finalidades de descobrir, nestes dados, padrões e regras significativos, e de fornecer subsídios para que possa ser feita uma previsão de tendências futuras baseada no passado. Os resultados obtidos com a mineração de dados podem ser usados no gerenciamento de informação, no processamento de pedidos de informação, na tomada de decisão, no controle de processo e em muitas outras aplicações. (BERRY; LINOFF, 1997).

A mineração de dados pode ser aplicada de duas formas: como um processo de verificação e como um processo de descoberta (GROTH, 1998). Na fase da verificação, é formulada uma hipótese sobre a relação entre os dados, e se tenta prová-la por meio de técnicas do tipo análises estatística e multidimensional, aplicadas sobre um banco de dados contendo informações passadas. Na fase da descoberta, não se fazem suposições antecipadas. Este processo usa técnicas, tais como a da descoberta de regras de associação, a das árvores de decisão, a dos algoritmos genéticos e a das redes neurais.

As técnicas de mineração de dados podem ser aplicadas a tarefas como classificação, estimativa (ou regressão), associação, segmentação e sumarização (FREITAS, 2000; FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996). A técnica de redes neurais é apropriada às seguintes tarefas: classificação, estimativa e segmentação.

De todas as técnicas citadas acima, este estudo será centrado no desenvolvimento de redes neurais artificiais para o propósito de estimativa, passando a uma fundamentação teórica específica sobre esta importante técnica, que pretende reproduzir características da inteligência humana em máquinas construídas pelo homem.

2.1 REDES NEURAIAS ARTIFICIAIS – FUNDAMENTAÇÃO TEÓRICA

Segundo Braga, Carvalho e Ludermir (2000), as Redes Neurais Artificiais – RNAs são também conhecidas como connexionismo ou sistema de processamento paralelo e distribuído.

Este modo de computação não-algorítmica é caracterizado por sistemas que se assemelham à estrutura do cérebro humano.

Conforme Braga, Carvalho e Ludermir (2000), o cérebro humano contém algo em torno de 10^{11} neurônios, sendo que cada um deles processa e se comunica com milhares de outros de modo contínuo e paralelo. O cérebro humano, entre outras funções, é responsável pelo pensamento, percepção e cognição. Além disto, sua rede de nodos tem a capacidade de reconhecer padrões e relacioná-los, usar e armazenar conhecimento por experiência e interpretar observações. Apesar de todos os estudos já realizados, ainda não se sabe ao certo a forma como as funções cerebrais são realizadas. O que se tem, até o momento, são modelos (ditos “redes neurais artificiais”) baseados na estrutura fisiológica básica destas redes de nodos naturais. No entanto, do ponto de vista físico, as redes artificiais se diferem bastante das redes biológicas. Destaca-se, contudo, as similaridades entre estes dois tipos de sistemas, buscando-se entender melhor o sistema nervoso, com idéias e inspirações para a pesquisa em neurocomputação. Como características comuns, pode ser citado que os dois tipos de sistemas são baseados em unidades de processamento paralelas e distribuídas, que se comunicam por meio de conexões sinápticas, possuem detectores de características, redundância e modularização das conexões. Estas características comuns permitem às RNAs reproduzir com fidelidade várias funções somente encontradas nos seres humanos. O futuro da neurocomputação se beneficiará, cada vez mais, do desenvolvimento de modelos que tenham apelo biológico, pois outras estruturas encontradas nos sistemas biológicos podem inspirar o desenvolvimento de novas arquiteturas para modelos de RNAs. Similarmente, espera-se que a Biologia e as Ciências Cognitivas possam se beneficiar de desenvolvimento de tais modelos de neurocomputação (BRAGA; CARVALHO; LUDERMIR, 2000).

Construir máquinas inteligentes tem sido um dos objetivos mais almejados pela comunidade científica e tecnológica. Neste contexto, para Carbonell, apud Goedtel (2003), a aprendizagem das máquinas vem ocupando posição de destaque no campo da Inteligência Artificial – IA. Surgiram vários paradigmas simbólicos de aprendizado, desenvolvidos na forma de métodos computacionais poderosos, na obtenção de conceitos por formas indutivas: sistemas classificadores e de aprendizado com base em explicações, trazendo grande interesse por estes métodos, no estudo de métodos para a solução de problemas complexos.

Ainda com respeito à aprendizagem, para Haykin (2001), o procedimento utilizado para a realização de tal processo é chamado de algoritmo de aprendizagem, cuja função é

modificar os pesos sinápticos da rede, de uma forma ordenada, para alcançar um objetivo de projeto desejado.

As RNAs, conforme Braga, Carvalho e Ludermir (2000), caracterizam-se por sistemas paralelos distribuídos, compostos por unidades de processamento simples (nodos) que calculam determinadas funções matemáticas (em geral, não-lineares). Estas unidades são dispostas em uma ou várias camadas interligadas por conexões – em geral uni-direcionais, às quais estão associados pesos, que armazenam o conhecimento representado no modelo, ponderando cada entrada recebida de cada neurônio da rede. A inspiração para o funcionamento de tais redes está baseada em uma das mais complexas estruturas físicas concebidas pela natureza: o cérebro humano.

É com base em tal ferramenta computacional que se consegue desenvolver modelos capazes de realizar previsões sobre o comportamento de diversos processos, bem como executar ações que visem o controle adequado dos mesmos.

Deste modo, a solução de problemas por meio de RNAs é bastante atrativa, uma vez que estas são representadas internamente pelo paralelismo natural inerente à sua arquitetura, criando a possibilidade de um desempenho superior ao dos modelos convencionais. Esta característica se deve a que uma RNA é capaz de realizar um processo de *aprendizagem*, quando um conjunto de exemplos (dados de uma amostra) lhe é apresentado, que por sua vez extrai, automaticamente, as características necessárias para representar a informação fornecida. Tais características são armazenadas sob a forma de pesos posteriormente utilizadas para gerar respostas para o problema (BRAGA; CARVALHO; LUDERMIR 2000).

A literatura pertinente ao tema reporta uma vasta gama de exemplos de aplicação bem sucedidos, nos mais diversos setores, como, por exemplo:

- a) reconhecimento de voz;
- b) reconhecimento de texto (OCR em scanners);
- c) avaliação de risco financeiro;
- d) prospecção petrolífera;
- e) análise e processamento de sinais;
- f) controle de processos;
- g) classificação de dados;

h) inúmeras outras aplicações.

Segundo Goedel (2003), tem havido um aumento quase que diário nas aplicações com redes neurais, principalmente em se tratando de não-linearidades. Este emprego se tornou particularmente atraente a partir do aumento do poder computacional dos microprocessadores, retirando este campo de estudos do ceticismo em que se encontrava, de meados dos anos 60 até o início da década de 80. Neste período, o interesse pela área retornou, devido, em grande parte, ao surgimento de novos modelos neurais e de algoritmos de aprendizado mais poderosos.

2.1.1 Neurônio biológico

Antes de se falar do neurônio artificial propriamente dito, é necessário citar que sua origem surgiu por meio de modelagem de um neurônio biológico, que, segundo Braga, Carvalho e Ludermir (2000), é dividido em três seções: o corpo da célula, os dendritos e o axônio, cada um com funções específicas, porém complementares. O corpo do neurônio mede apenas alguns milésimos de milímetro, e os dendritos apresentam poucos milímetros de comprimento. O axônio é mais longo, e, em geral, tem calibre uniforme. Os dendritos têm por função receber as informações (impulsos nervosos) oriundas de outros neurônios e conduzi-las até o corpo celular, onde é processada, gerando novos impulsos, que são transmitidos a outros neurônios, passando através do axônio até os dendritos dos neurônios seguintes. O ponto de contato entre um axônio e um dendrito é chamado de sinapse. É através das sinapses que os nodos se unem funcionalmente, formando redes neurais. As sinapses funcionam como válvulas, e são capazes de controlar a transmissão de impulsos (fluxo de informação) entre os nodos na rede neural. O efeito das sinapses é variável, o que dá ao neurônio sua capacidade de adaptação. Os sinais provindos dos neurônios pré-sinápticos são transmitidos para o corpo do neurônio pós-sináptico, onde são comparados com os outros sinais recebidos pelo mesmo (Figura 2).

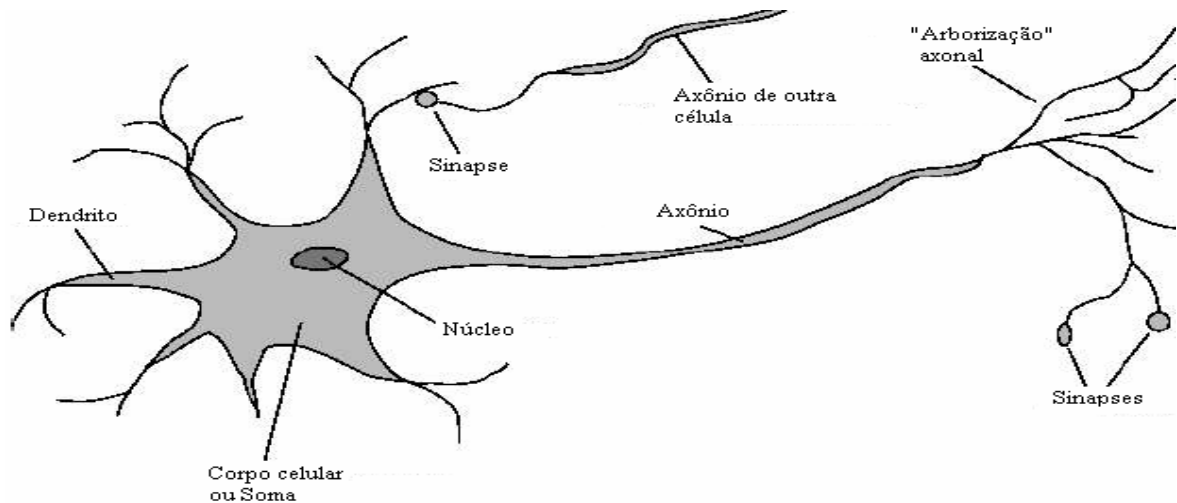


Figura 2 – Neurônio biológico.

Fonte: adaptado de Braga, Carvalho e Ludermir (2000).

Se o potencial de um intervalo curto de tempo é suficientemente alto, a célula “dispara”, produzindo um impulso que é transmitido para as células seguintes (nodos pós-sinápticos). Para que este disparo ocorra, é preciso que os impulsos das sinapses reduzam este nível para cerca de -50 mV . Neste momento, o fluxo de sódio e de potássio é invertido, e o gradiente do interior da célula torna-se, subitamente, positivo em relação ao exterior. Esta inversão de gradiente se traduz em uma alteração na polaridade de sua membrana, que faz com que o impulso nervoso se propague pelo axônio até suas conexões sinápticas, seguindo-se um período de descanso (Figura 3). Este sistema simples é responsável pela maioria das funções realizadas pelo cérebro humano. A capacidade de realizar funções surge com a operação em paralelo de todos os 10^{11} nodos do cérebro (BRAGA; CARVALHO; LUDERMIR, 2000).

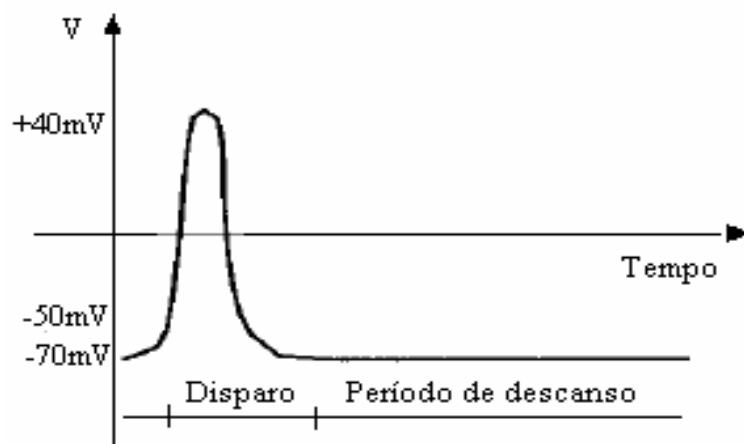


Figura 3 – Potencial de ação de um neurônio

Fonte: Braga, Carvalho e Ludermir (2000).

2.1.2 Neurônio artificial

Segundo Braga, Carvalho e Ludermir (2000), um modelo inicial de um neurônio artificial foi proposto por McCulloch e Pitts (modelo MCP), em 1943, que consiste de uma simplificação do que se sabia até então a respeito do neurônio biológico. A descrição matemática resultou em um modelo com n terminais de entrada $x_1, x_2, x_3, \dots, x_n$, que representam os dendritos, e apenas um terminal de saída y , representando o axônio. Para emular o comportamento das sinapses, os terminais de entrada do neurônio têm pesos acoplados $w_1, w_2, w_3, \dots, w_n$, cujos valores podem ser positivos ou negativos, dependendo de as sinapses correspondentes serem inibitórias ou excitatórias. O efeito de uma sinapse particular i no neurônio pós-sináptico é dado por $x_i \cdot w_i$. Os pesos determinam em que grau o neurônio deve considerar sinais de disparo que ocorrem naquela conexão. A Figura 4, a seguir, ilustra esse modelo.




Figura 4 – Neurônio de McCulloch e Pitts

Fonte: Braga, Carvalho e Ludermir (2000).

Para Haykin (2001), um neurônio é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural.

No modelo MCP, a ativação do neurônio é obtida através da aplicação de uma função de ativação, que ativa ou não a saída, dependendo do valor da soma ponderada das suas entradas (Equação 2.1). O nodo MCP terá sua saída ativada quando:

$$\sum_{i=1}^n x_i \cdot w_i \geq q \quad (2.1)$$

onde q é o limiar (*threshold*) do neurônio.

Com o tempo, o modelo inicial de neurônio, proposto por McCulloch e Pitts, foi aperfeiçoado, passando a ser apresentado como o diagrama da Figura 5, que se constitui como a base para o projeto de redes neurais artificiais.




Figura 5- Modelo de um neurônio (aperfeiçoado).

Fonte: Haykin (2001).

O neurônio artificial assim proposto é associado computacionalmente a uma estrutura matricial, com as entradas $x_1, x_2, x_3, \dots, x_m$ e uma saída y . Como já foi citado anteriormente, cada entrada tem seu peso associado $w_1, w_2, w_3, \dots, w_m$, que pondera quantitativamente cada entrada em relação à saída. O produto da entrada pelos pesos determina a primeira operação matemática de um neurônio artificial (equação 2.1), juntamente com um limiar de ativação do neurônio b (*bias*). O *bias* tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente conforme ilustrado na Figura 5 (HAYKIN, 2001). O resultado dessa soma v é a variável independente de uma função de ativação $\mathbf{j}(\cdot)$, que faz a correspondência do somatório anterior com a saída y , atuando de modo a limitar a amplitude do sinal de saída.

Deste modo, pode-se descrever um neurônio artificial através do seguinte conjunto de equações:

$$u = \sum_{j=1}^m x_j \cdot w_j \quad (2.2)$$

$$v = (u + b) \quad (2.3)$$

$$y = \mathbf{j}(v) \quad (2.4)$$

onde:

m é o número de entradas do neurônio;

x_j é a j -ésima entrada do neurônio;

w_j é o peso atribuído à j -ésima entrada do neurônio;

b é o limiar de ativação do neurônio;

v é a variável de entrada (ou potencial de ativação) da função de ativação do neurônio;

e

y é a saída do neurônio

A equação (2.4) acima, $y = \mathbf{j}(v)$, representa a própria função de ativação do neurônio.

O limiar de ativação (*bias*) tem a finalidade de aumentar ou diminuir os valores resultantes da soma dos produtos de todos os vetores de entrada pelos respectivos pesos (equação 2.2). A variável v , vista na Figura 5, representa a saída do bloco somador, e, conforme Haykin (2001), é classificada como campo local induzido. A relação entre o campo local induzido e o combinador linear das entradas (equação 2.3) se altera de acordo com o valor de b . Tais alterações encontram-se mapeadas na Figura 6:

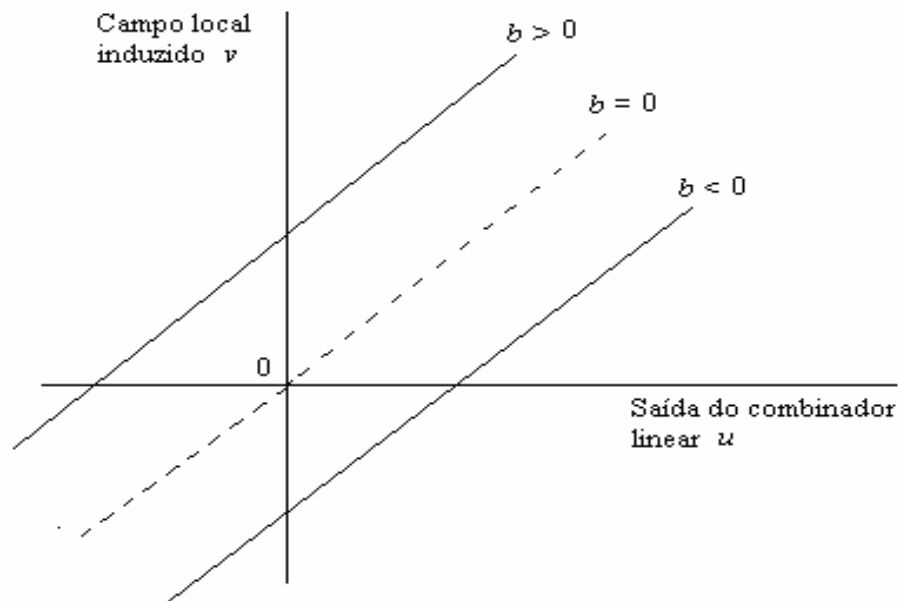


Figura 6 – Transformação afim produzida pela presença de um bias.

Fonte: Haykin (2001).

As *funções de ativação*, representadas por $\mathbf{j}(\cdot)$, limitam a variação do sinal de saída y do neurônio. A literatura pertinente ao assunto também trata estas funções de ativação como *funções restritivas*, ou, ainda, *funções de transferência*. Segundo Goedel (2003), essas funções de ativação podem assumir os seguintes valores:

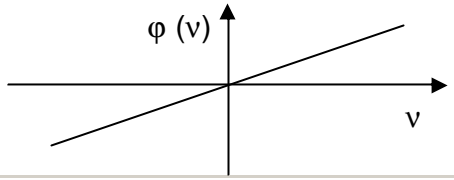
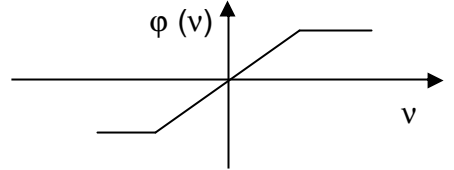
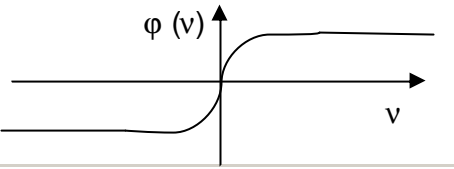
Binários unipolares (0 ou 1);

Binários bipolares (-1 ou 1); e

Reais.

De acordo com Braga, Carvalho e Ludermir (2000), as principais funções de ativação do neurônio artificial são:

Tipo de função	Equação	Gráfico
v Degrau Simétrico	$\mathbf{j}(v) = \begin{cases} +1, & \text{se } v \geq 0 \\ -1, & \text{se } v < 0 \end{cases}$	
v Degrau Simétrico Probabilístico	$\varphi(v) = \begin{cases} +1, & \text{com probabilidade } P(v) \\ -1, & \text{se com probabilidade } 1 - P(v) \end{cases}$	
Continua...		

Tipo de função	Equação	Gráfico
Continuação.		
Linear Irrestrita	$j(v) = av$	
Saturação	$j(v) = \begin{cases} +1, & \text{se } v \geq a \\ v, & \text{se } -a < v < a \\ -1, & \text{se } v \leq -a \end{cases}$	
Sigmóide ou Logística	$j(v) = \frac{1}{1 + e^{-bv}}$	

Quadro 1 – Principais funções de ativação do neurônio artificial

Fonte: Braga, Carvalho e Ludermir (2000).

O modelo neuronal descrito anteriormente é determinístico, visto que o seu comportamento de entrada e saída é definido precisamente para todas as entradas. Em algumas aplicações, é desejável que a análise esteja baseada em um modelo de neurônio estocástico, onde se dá uma interpretação probabilística à função de ativação do modelo de McCulloch-Pitts. No Quadro 1 se apresenta a função degrau simétrico probabilístico. De acordo com Haykin (2001), $P(v)$ é uma função sigmóide:

$$P(v) = \frac{1}{1 + \exp(-v/T)} \quad (2.5)$$

onde:

v é o campo local induzido do neurônio; e

T parâmetro que representa o ruído sináptico.

Os primeiros modelos de redes neurais, chamados perceptron, eram constituídos por um único neurônio (ver Figura 5). Estes modelos consistem de um combinador linear das entradas aplicadas às sinapses, incorporando também um *bias* aplicado externamente. A soma resultante (campo local induzido) é aplicada a um limitador abrupto (realizando a função de sinal). Deste modo, o neurônio produz uma saída igual a +1 se a entrada do limitador abrupto for positiva e -1 se ela for negativa (vide função degrau, Tabela 1). O perceptron assim

construído, isto é, com um único neurônio, serve unicamente às classificações de padrões linearmente separáveis, que se encontram em lados opostos de um hiperplano (HAYKIN, 2001).

Haykin (2001) salienta que a função de ativação do tipo sigmóide, ou função logística é a mais utilizada em redes neurais, como ilustrado na Tabela 1. A principal vantagem desta função é que ela é diferenciável, característica considerada importante na teoria de redes neurais. Devido à natureza dos dados envolvidos, a rede neural deste estudo usará esta função para ativação dos neurônios em suas camadas ocultas.

2.1.3 Arquitetura de redes neurais artificiais

A arquitetura de uma Rede Neural Artificial (RNA) é um parâmetro importante de sua concepção, já que a mesma é restringida pelo problema que irá resolver. As redes de camada única de nodos MCP conseguem apenas resolver problemas linearmente separáveis. Redes recorrentes são mais apropriadas para resolver problemas que envolvem processamento temporal na definição de uma arquitetura, levando-se em conta os seguintes parâmetros: número de camadas da rede, número de nodos em cada camada, tipo de conexão entre os nodos e topologia da rede (BRAGA; CARVALHO; LUDERMIR, 2000).

Segundo Haykin (2001) e Goedtel (2003), a estrutura de uma rede neural é, basicamente, composta por três camadas. A primeira delas é denominada camada de entrada, responsável apenas pela recepção do vetor de variáveis, com as informações a serem processadas pelo restante da rede. A segunda camada é denominada camada intermediária ou oculta, que pode ser única ou com várias sub-camadas, em cascata. Esta é a camada responsável pelo processamento da informação recebida pela camada de entrada. O processamento é realizado de forma paralela, passando pelos diversos neurônios da camada intermediária. A seguir, tem-se a camada de saída – a última – responsável pela fase final do processamento e apresentação dos resultados.

A Figura 7 a seguir descreve uma arquitetura de redes neurais, com suas respectivas camadas.




Figura 7 – Exemplo de arquitetura de uma RNA.

Fonte: Braga, Carvalho e Ludermir (2000).

A arquitetura da rede neural está intimamente ligada com o seu algoritmo de aprendizagem, usado no seu treinamento, para o ajuste dos pesos sinápticos dos neurônios de cada uma de suas camadas (HAYKIN, 2001).

A literatura menciona três classes de arquiteturas de redes neurais: redes alimentadas adiante com camada única, redes alimentadas diretamente com múltiplas camadas e redes recorrentes (BRAGA; CARVALHO; LUDERMIR, 2000; HAYKIN, 2001; GOEDEL, 2003).

O interesse deste trabalho está nas redes alimentadas diretamente com múltiplas camadas – *Feedforward Multilayer Network*, apresentado na seção seguinte.

As equações (2.2), (2.3) e (2.4) foram escritas para um único neurônio, com m entradas. Estas equações podem facilmente ser expandidas para vários neurônios e várias camadas, cada qual com seus pesos e *bias* (Figura 8). Neste caso, será conveniente indexar as variáveis e parâmetros para o respectivo neurônio e sua camada. Assim, para o k -ésimo neurônio de uma determinada camada, tem-se:

$$u_k = \sum_{j=1}^m x_j \cdot w_{kj} \quad (2.6)$$

$$v_k = (u_k + b_k) \quad (2.7)$$

$$y_k = \mathbf{j}(v_k) \quad (2.8)$$

onde:

m é o número de entradas do neurônio k ;

$$j = 1, 2, \dots, m$$

x_j é a j -ésima entrada do neurônio k ;

w_{kj} é o peso atribuído à j -ésima entrada do neurônio k ;

b_k é o limiar de ativação do neurônio k ;

u_k é a saída do combinador linear do neurônio k ;

v_k é a variável de entrada (ou potencial de ativação) da função de ativação do neurônio k ;

y_k é a saída do neurônio.

A função de ativação j – não-linear – é usada para calcular a saída y_k de cada neurônio

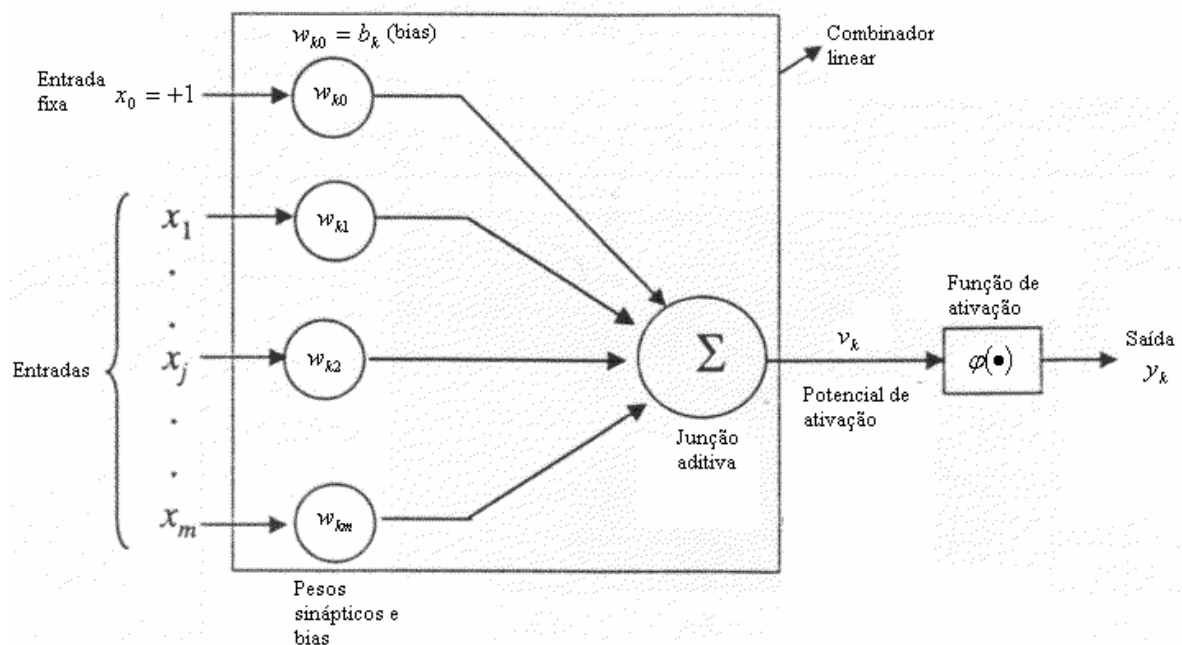


Figura 8 – Representação do modelo não-linear de um neurônio inserido em camadas de uma rede neural

Fonte: Haykin (2001).

A notação aqui utilizada – bem como a notação utilizada mais adiante – é sugerida por Haykin (2001), onde os índices i , j e k se referem a neurônios diferentes na rede; com os sinais se propagando através da rede da esquerda para a direita. O neurônio j se encontra em uma camada à direita do neurônio i , e o neurônio k se encontra em uma camada à direita do neurônio j , quando o neurônio j é uma unidade oculta.

Com base nas considerações feitas até aqui, uma rede neural artificial é constituída de unidades bastante simples: o neurônio artificial (Figura 5), cujos elementos se encontram descritos na seção correspondente, e que é definido, matematicamente, por um pequeno conjunto de equações (2.2 a 2.4) e um algoritmo de treinamento. O cascadeamento entre um conjunto de neurônios – ou elementos de processamento – e o paralelismo formam a topologia da rede, que, através do grande número de conexões – e de seus respectivos pesos – entre estes elementos de processamento, transforma a rede neural em uma poderosa ferramenta para a resolução de uma inumerável quantidade de problemas, conforme citado na seção 2.1.

Assim, as redes neurais possuem várias características vantajosas que estimulam as pesquisas na área:

- a) controle altamente paralelo e distribuído;
- b) qualidade superior: as redes permitem análises superiores às conseguidas com técnicas estatísticas;
- c) competitividade: empresas que tenham conseguido redes bem elaboradas possuem maior "poder de fogo" frente aos seus concorrentes, dado que esta é uma tecnologia ainda nova e pouco conhecida;
- d) auto-aprendizado: baseiam-se unicamente nos exemplos históricos que lhes são fornecidos;
- e) implementação mais rápida: o tempo necessário para se implementar uma rede é menor do que o utilizado para a construção de um sistema especialista equivalente, além do menor custo envolvido.
- f) capacidade de generalização: mesmo com dados incompletos ou imprecisos, as redes podem preencher as lacunas sem sofrer degradação;
- g) imunidade a ruídos: os dados reais sempre contêm ruído (variações aleatórias adicionadas aos valores originais); as redes conseguem separar o ruído da informação relevante;
- h) adaptabilidade: uma vez construída uma rede eficiente em dada aplicação, ela pode ser utilizada em aplicações de tempo-real, sem necessidade de ter sua arquitetura alterada a cada atualização; basta que seja retreinada com base nos novos dados históricos que forem surgindo;

i) democratização: arquiteturas gerais que podem ser encapsuladas em softwares, facilitando o seu uso por parte dos executivos na tomada de decisão (DAHMER, 1998).

Também são apontadas algumas desvantagens, que requerem bom-senso na resolução de problemas por meio de redes neurais artificiais:

a) resultados desconcertantes: as redes podem chegar a conclusões que contrariem as regras e teorias estabelecidas;

b) hardware de alta tecnologia: um *Personal Computer (PC)* pode ser suficiente, mas um *Cray* é sempre uma possibilidade não desprezível; podem ser necessárias placas especiais de processamento paralelo, além de um co-processador aritmético;

c) caixa-preta: é impossível saber porque a rede chegou a tal conclusão; seus critérios decisórios são encriptados, não se sabendo até o momento que pesos são relevantes à tomada de uma dada decisão; os milhares de pesos não aceitam interpretação e nem são passíveis de interpretação lógica: sabe-se apenas que funcionam;

d) grande volume de dados: para uma rede poder aprender corretamente necessita de milhares de dados históricos; a carência de dados passados relevantes em quantidade suficiente pode tornar a rede inaplicável;

e) trabalho artesanal: não há regras gerais para se determinar o volume de dados de entrada para treinamento, quantas camadas ocultas devem ser utilizadas, a melhor estratégia de treinamento (DAHMER, 1998).

2.1.4 Perceptron de múltiplas camadas

Conforme Haykin (2001), historicamente as redes neurais tiveram contribuições importantes de pesquisadores como McCulloch e Pitts (1943), que introduziram a idéia de redes neurais como máquinas computacionais; Hebb *apud* Haykin (2001), que postulou a primeira regra de aprendizagem auto-organizada e Rosenblatt *apud* Haykin (2001), que propôs o perceptron como o primeiro modelo para aprendizagem com um professor (aprendizagem supervisionada).

A unidade fundamental do perceptron é o neurônio não-linear, ou Modelo de McCulloch-Pitts de um neurônio, apresentado na Figura 5 e descrito na seção correspondente.

O perceptron é uma das mais importantes classes de redes neurais de múltiplas camadas alimentadas adiante, tendo como principais características:

- a) cada neurônio da rede possui uma função de ativação não-linear (função logística ou sigmóide);
- b) a rede contém uma ou mais camadas de neurônios ocultos; e
- c) a rede exibe um alto grau de conectividade, determinado por suas sinapses.

Para Haykin (2001), a camada oculta é incluída para permitir que a rede extraia as características intrínsecas do processo, estabelecendo, no treinamento, a relação entrada-saída pelo ajuste de seus pesos sinápticos, e, com isto, formando sua memória de longo prazo utilizada na generalização de resultados para o domínio específico das variáveis de entrada.

2.1.5 Aprendizagem de redes neurais artificiais

As RNAs possuem a capacidade de *aprender* por exemplos e fazer interpolações e extrapolações do que aprenderam. Neste contexto, *aprender* significa tão somente definir um conjunto adequado de pesos w_i e de limiar de ativação b , que forneçam, na saída y do neurônio uma resposta tão próxima quanto possível do valor esperado. No aprendizado conexionista, não se procura obter regras como na abordagem simbólica da Inteligência Artificial (IA), mas sim determinar a intensidade de conexões entre neurônios. Um conjunto de procedimentos bem-definidos para adaptar os parâmetros de uma RNA (seus pesos w_i e seu limiar de ativação b), para que a mesma possa aprender uma determinada função, que é chamado de *algoritmo de aprendizado*. A rede extrai informações de padrões de informação apresentados para ela, criando uma representação própria para o problema. Trata-se de um processo iterativo de ajuste de parâmetros da rede, no qual os pesos das conexões entre as unidades de processamento guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente no qual está operando (BRAGA; CARVALHO; LUDERMIR, 2000).

Dentre os diversos métodos de aprendizagem no treinamento de uma RNA, destaca-se, para os propósitos deste estudo, o aprendizado supervisionado.

Segundo Refenes (1995), o aprendizado supervisionado – no qual o agente supervisor é metaforicamente chamado de professor – ou retropropagação do erro (*backpropagation*), é o algoritmo mais utilizado para o ajuste dos pesos da rede neural, por meio da minimização do erro (também chamado de *função de custo*, que será visto na seção seguinte) na camada de saída da rede. O processo se repete até que se atinja o ponto ótimo, que é determinado pelo menor erro (Figura 9).

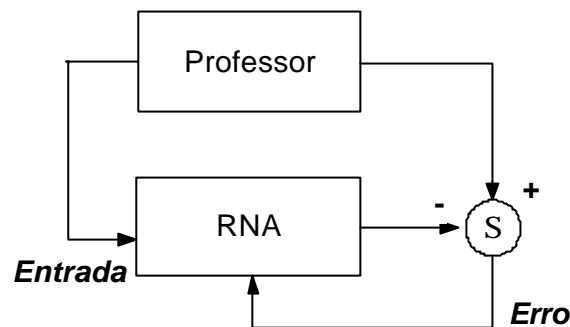


Figura 9 – Aprendizado supervisionado

Fonte: Braga, Carvalho e Ludermir (2000).

A desvantagem do aprendizado supervisionado, segundo Braga, Carvalho e Ludermir (2000), é que, na ausência do professor, a rede não conseguirá aprender novas estratégias para situações não cobertas pelos seus exemplos de treinamento. Os exemplos mais conhecidos são a regra delta (ver seção 2.1.6) e sua generalização para redes de múltiplas camadas, o já citado algoritmo *backpropagation*. (BRAGA; CARVALHO; LUDERMIR, 2000).

Para Haykin (2001), a aprendizagem é a propriedade de fundamental importância para uma rede neural, para melhorar seu desempenho, que ocorre com o tempo, a partir de uma medida preestabelecida. Uma rede neural aprende acerca de seu ambiente através de um processo iterativo de ajustes aplicados a seus pesos sinápticos e níveis de *bias*. Idealmente, a rede se torna mais instruída sobre o seu ambiente após cada iteração do processo de aprendizagem.

O algoritmo de aprendizagem é definido por um conjunto de regras bem-definidas para a solução de um problema de aprendizagem. Não há um algoritmo de aprendizagem único para o projeto de redes neurais, posto que os mesmos diferem na maneira pela qual o ajuste dos pesos é feito. O que se tem, na verdade, é um conjunto de ferramentas, representado por uma variedade de algoritmos, cada qual oferecendo vantagens específicas,

diferindo entre si na forma como o ajuste de um peso sináptico de um neurônio é formulado. Há que se considerar, também, a maneira pela qual uma rede neural constituída de um conjunto de neurônios interligados se relaciona com o seu ambiente, ou seja, trata-se de um paradigma de aprendizagem referente a uma modelagem do ambiente no qual a rede neural irá operar.

2.1.6 Algoritmo de treinamento

O algoritmo *backpropagation* mencionado na seção anterior é também conhecido como Regra Delta Generalizada para o treinamento das redes perceptron multicamadas (GOEDEL, 2003).

A regra delta, cujo equacionamento é apresentado mais adiante, é formulada como:

“O ajuste feito em um peso sináptico de um neurônio é proporcional ao produto do sinal de erro pelo sinal de entrada da sinapse em questão (HAYKIN, 2001).”

O algoritmo ocorre sob a forma de dois passos, um para a frente, ou *forward* e outro para trás, ou *backward* (Figura 10).




Figura 10 – Ilustração das direções de dois fluxos de sinal básicos em um perceptron de múltiplas camadas: a propagação para frente de sinais funcionais e a retropropagação de sinais de erro.

Fonte: Braga, Carvalho e Ludermir (2000).

No passo para a frente, ou *forward*, a informação entregue à entrada da rede se propaga camada por camada, até atingir sua saída. Nesta fase, não há alteração dos pesos sinápticos da rede.

O passo *backward* consiste em percorrer o caminho inverso ao anterior, isto é, partindo-se da saída, o erro é calculado e levado de volta, promovendo o ajuste das matrizes de pesos sinápticos (GOEDTEL, 2003).

Conforme demonstra Haykin (2001), o erro produzido na saída da rede é usado para o ajuste de seus parâmetros (pesos e limiares), que será abordado mais adiante. O processo acontece de modo iterativo. Parte-se de uma base de dados de aprendizagem (vetor conhecido de entradas e saídas), realizando-se as fases *forward* e *backward* para cada elemento do vetor de treinamento, sucessivamente. A cada iteração, os pesos e *bias* são modificados, sempre na fase *backward*, segundo algum critério de ajuste de erros.

O erro na saída do neurônio j , para a iteração n , é definido por:

$$e_j(n) = d_j(n) - y_j(n) \quad (2.9)$$

onde:

n representa o *passo* do processo iterativo no ajuste de pesos do neurônio j

$d_j(n)$ é a resposta desejada do neurônio j associado à n -ésima iteração;

$y_j(n)$ é a saída do neurônio j calculado na n -ésima iteração; e

$e_j(n)$ é o erro do neurônio j associado à n -ésima iteração.

Para Haykin (2001), o sinal de erro $e_j(n)$ aciona um *mecanismo de controle* com o propósito de aplicar uma seqüência de ajustes corretivos aos pesos sinápticos do neurônio j . Estes ajustes visam aproximar, passo a passo, a saída $y_j(n)$ da resposta desejada $d_j(n)$. O objetivo é alcançado pela minimização de uma *função de custo* ou *índice de desempenho*, ou *energia instantânea de erro*, $\mathbf{e}(n)$, cujo valor instantâneo é obtido pela soma de todos os erros quadráticos produzidos pelos neurônios da camada de saída, que são os únicos neurônios *visíveis*, para os quais os sinais de erro podem ser calculados diretamente. Assim, pode-se escrever

$$\mathbf{e}(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (2.10)$$

onde, segundo Haykin (2001), $1/2$, é introduzido para simplificar a análise subsequente – minimização de $e(n)$ e ajuste dos pesos sinápticos – e o conjunto C inclui todos os neurônios da camada de saída da rede. Considerando-se N como o número total de exemplos contidos no conjunto de treinamento, a *energia média do erro quadrado* é obtida pela soma dos $e(n)$ para cada um dos n passos do processo iterativo e normalizada em relação ao tamanho do conjunto, N , ou

$$e_{med} = \frac{1}{N} \sum_{n=1}^N e(n) \quad (2.11)$$

A energia instantânea do erro, $e(n)$, e conseqüentemente a *energia média do erro* e_{med} , é uma função de todos os parâmetros livres (pesos sinápticos e níveis de bias) da rede. Para um dado conjunto de treinamento, e_{med} representa a *função de custo* como uma medida do desempenho de aprendizagem. O objetivo do processo de aprendizagem é ajustar os parâmetros livres da rede para minimizar e_{med} (HAYKIN, 2001).

Para a consecução deste processo, são utilizadas técnicas do cálculo diferencial (derivadas parciais), com determinação da função gradiente, cujos detalhes metodológicos para os ajustes dos pesos sinápticos por correção de erro encontram-se em Haykin (2001).

Os pesos sinápticos têm seus valores atualizados da seguinte forma:

$$w_{ji}(n+1) = w_{ji}(n) + \Delta w_{ji}(n) \quad (2.12)$$

onde:

$w_{ji}(n+1)$ é o novo peso sináptico da j -ésima sinapse do neurônio i , em seu passo de iteração $(n+1)$;

$w_{ji}(n)$ é o antigo peso sináptico da j -ésima sinapse do neurônio i , em seu passo de iteração n ; e

$\Delta w_{ji}(n)$ é a correção aplicada a cada peso sináptico $w_{ji}(n)$.

A correção $\Delta w_{ji}(n)$ aplicada aos pesos $w_{ji}(n)$ é definida pela *regra delta* como:

$$\Delta w_{ji}(n) = \mathbf{hd}_j(n)y_i(n) \quad (2.13)$$

e

$$\mathbf{d}_j(n) = -\frac{\partial \mathbf{e}(n)}{\partial v_j(n)} \quad (2.14)$$

onde:

$\mathbf{d}_j(n)$ é o gradiente local, cujo sinal negativo em (2.14) indica a descida do gradiente no espaço de pesos, isto é, busca uma direção para a mudança de peso que reduza o valor de $\mathbf{e}(n)$.

\mathbf{h} é o parâmetro da taxa de aprendizagem do algoritmo de retropropagação;

$\Delta w_{ji}(n)$ é o ajuste aplicado ao peso sináptico $w_{ji}(n)$;

$y_i(n)$ saída do neurônio i precedente ao neurônio j .

Haykin (2001) salienta ainda que, quando o neurônio j está na camada de saída da rede, ele é suprido com uma resposta desejada particular. Deste modo, a equação (2.9) calcula o erro relativo a este neurônio. Para o gradiente local em questão, utiliza-se a equação (2.14). Entretanto, quando o neurônio estiver em uma camada oculta da rede, não existe uma resposta desejada especificada para este neurônio. Seu erro deve, então, ser determinado recursivamente, em termos dos sinais de erro de todos os neurônios aos quais o neurônio oculto está diretamente conectado. É neste ponto que o algoritmo de retropropagação torna-se complicado em termos de equacionamento matemático. Os detalhes deste equacionamento encontram-se em Haykin (2001).

Os ajustes passo a passo dos pesos sinápticos do neurônio continuam até o sistema chegar ao seu estado estável, com todos os seus pesos ajustados, quando o processo é encerrado.

A função de custo, $\mathbf{e}(n)$ forma uma superfície de erro que, quando complexa, leva o algoritmo a torna-se demasiadamente lento pelo método do gradiente descendente. Além disto, com frequência, pode levá-lo a convergir para mínimos locais, que são pontos na superfície de erro que apresentam uma solução estável, porém não ótima. Uma forma de minimizar este problema foi a introdução de uma taxa de *momentum* para o gradiente (BRAGA; CARVALHO; LUDERMIR, 2000).

O método de Gauss-Newton é aplicado ao problema de otimização, com o propósito de minimizar a aproximação quadrática da função de custo $\mathbf{e}(n)$, conforme a equação (2.8), que é expressa como a soma de erros quadrados, em torno de seus pesos sinápticos. Esta

minimização é realizada a cada iteração. O processo, descrito em Haykin (2001), calcula a matriz jacobiana do vetor de erro $J(n)$, que deve ter posto n em relação às linhas, isto é, as n linhas de $J(n)$ devem ser linearmente independentes, a fim de assegurar que o produto $J^T(n)J(n)$ seja não-singular. Entretanto, segundo Haykin (2001), nem sempre esta condição é satisfeita e a matriz jacobiana pode apresentar deficiência em posto.

Em 1963, Levenberg e Marquardt propuseram uma alteração no método dos mínimos quadráticos de Gauss-Newton, pela introdução de uma taxa variável que é somada ao produto $J^T(n)J(n)$, que resulta na variação do erro. O algoritmo *backpropagation* original poderia levar o erro a assumir valores negativos, uma vez que este diminuía a cada iteração, resultando em não-convergência. A alteração proposta por Levenberg e Marquardt tornou o algoritmo flexível, com a possibilidade de variar a taxa de erro, resolvendo, desta forma o problema de convergência (HAGAN; MENHAJ, 1994).

Hagan e Menhaj (1994) demonstram que o algoritmo de Levenberg-Marquardt é mais eficiente do que os algoritmos do gradiente conjugado e da taxa de aprendizagem variável, para redes com algumas centenas de pesos sinápticos.

O objetivo primordial no treinamento de uma rede neural é produzir os menores erros possíveis, mantendo sua capacidade de responder apropriadamente a novas variáveis de entrada, ou seja, de produzir generalizações adequadas. O método para aprimorar a capacidade de generalização da rede restringe o tamanho da própria rede com relação aos seus pesos sinápticos e é chamado de regularização (FORESEE; HAGAN, 1997).

O presente estudo empregou, no treinamento supervisionado das redes neurais, o algoritmo *backpropagation* com regularização bayesiana, conforme descrito em Foresee e Hagan (1997).

3 METODOLOGIA

O método utilizado neste estudo está baseado em técnicas de Pesquisa Operacional – PO.

Conforme Maçada (2001), a pesquisa que utiliza o método de PO deve se desenvolver segundo os passos apresentados a seguir, salientando-se que a seqüência não é rígida, mas indica as principais etapas a serem vencidas (WAGNER,1986; WINSTON, 1994):

- a) Definição do Problema;
- b) Construção do Modelo;
- c) Solução do Modelo;
- d) Validação do Modelo;
- e) Análise dos Resultados.

Shin et al. (2002), restringe os estágios acima a apenas três: (a) formulação – que se refere à geração do modelo em si; (b) solução – que se refere ao algoritmo utilizado; e (c) análise – que diz respeito às interpretações do modelo para um conjunto de soluções.

Conforme Wagner (1986), a análise quantitativa de um modelo de PO é precedida por uma análise qualitativa do problema, isto é, por um diagnóstico que identifique os fatores importantes para a construção do modelo, bem como sua solução e validação, seguido por análise dos resultados.

Para este estudo, foram seguidas as técnicas indicadas na literatura sobre redes neurais para a implementação do modelo de predição, sua solução e a conseqüente análise dos resultados.

Segundo Setyawati, Creese e Sahirman (2003), os principais fatores que devem pautar a modelagem de um sistema, baseado em RNA, são:

- a) seleção das variáveis de entrada;
- b) quantidade de variáveis;
- c) arquitetura da rede;

- d) treinamento;
- e) previsão da saída.

Entretanto, para Setyawati, Creese e Sahirman (2003), há um problema a ser contornado na consecução da modelagem: não há uma regra fixa para a determinação da arquitetura apropriada, nem para seus parâmetros.

Em outras palavras, neste campo de estudos ainda há um grande predomínio do empirismo, com uma diversidade de teorias formuladas acerca do mesmo, o que ainda não proporcionou a composição de um paradigma que permitisse, ao menos, constituir conclusões definitivas (GOEDTEL, 2003). Pode-se dizer que tal paradigma encontra-se em sua fase de construção (COURTNEY, 2001).

Alguns pesquisadores estudaram os efeitos de alguns fatores-chave para a modelagem de várias aplicações. Argumenta-se que o modelo com uma camada oculta é suficiente para funções contínuas e séries temporais (SETYAWATI; CREESE; SAHIRMAN, 2003).

A importância das variáveis de entrada é destacada por Fish e Blodgett (2003). Já a preparação dos dados é crucial para o desempenho da rede neural. A transformação dos dados em intervalos $[0, 1]$ é recomendada em séries temporais. O número de entradas desempenha papel importante na precisão. Quanto mais treinada a rede, maior sua precisão (SETYAWATI; CREESE; SAHIRMAN, 2003).

A ferramenta utilizada no desenvolvimento das redes neurais do presente estudo, o software *Matrix Laboratory – MATLAB*, realiza uma transformação no intervalo $[-1, 1]$ que, conforme será visto mais adiante, é mais eficaz no trato com a função de ativação das camadas ocultas da rede: tangente sigmóide, cujo gráfico é apresentado na Tabela 1.

Outro fator relevante é a complexidade da superfície de erro da chamada função de custo, $e(n)$. Conforme já foi citado na seção 2.2.6, freqüentemente o método da minimização do erro conduz o algoritmo a convergir para mínimos locais. Deste modo, após várias seções de treinamento, ocorrem erros de treinamento – e também de predição – diferentes. Com os propósitos de minimizar este problema e de tornar os resultados mais confiáveis, para cada algoritmo deste estudo, foi realizado um conjunto de 20 sessões independentes de treinamento, tomando-se aquele resultado que apresentasse o menor erro de predição.

3.1 VARIÁVEIS SELECIONADAS

Este estudo partiu de uma amostra-piloto, da qual constaram dados secundários dos 24 municípios do Estado do Rio Grande do Sul nos quais está presente uma estação climatológica ou agroclimatológica, a saber: Bagé, Bento Gonçalves, Bom Jesus, Camaquã, Cambará do Sul, Campo Bom, Caxias do Sul, Cruz Alta, Encruzilhada do Sul, Ibirubá, Iraí, Lagoa Vermelha, Passo Fundo, Pelotas, Porto Alegre, Rio Grande, Santana do Livramento, Santa Maria, São Luiz Gonzaga, Santa Vitória do Palmar, Teutônia, Torres, Triunfo e Uruguiana.

Conforme Bolzern e Fronza (1986), a variável temperatura ambiental constitui-se em um forte indicador de demanda de energia elétrica.

De acordo com o Instituto de Meteorologia – INMET, a sensação térmica, ou efeito *wind chill* é a temperatura virtual ou a combinação da temperatura com outros fatores meteorológicos, como o vento, que representa com mais precisão o impacto das condições do tempo sobre o organismo humano. Devido à dificuldade em se tabular a variável velocidade do vento para este estudo, foi utilizada a umidade relativa do ar, como variável associada à temperatura, para compor o efeito da sensação térmica.

Os dados de temperatura e umidade relativa do ar foram obtidos no Oitavo Distrito de Meteorologia – 8º Disme, para cada uma das 24 estações climatológicas supracitadas, com periodicidade mensal, entre os anos de 1999 e 2002.

Segundo dados do Balanço Energético Nacional (BRASIL. MINISTÉRIO DE MINAS E ENERGIA 2004), os requisitos de mercado são estimados com base em hipóteses sobre a evolução provável de um conjunto de variáveis macro-econômicas, demográficas e habitacionais. Com base nestas considerações, foram selecionadas as variáveis Produto Interno Bruto – PIB e população anuais de cada município para o período entre 1999 e 2002 (TERRAGAUCHA, 2003).

Dados de demanda de energia elétrica no Estado do Rio Grande do Sul, em cada um dos setores, foram levantados na Fundação de Economia e Estatística do Estado do Rio Grande do Sul – FEE, da Secretaria da Coordenação e Planejamento do Estado do Rio Grande do Sul.

Com o propósito de compor uma base de dados que apresentasse compatibilidade na referência de tempo, as variáveis temperatura e umidade relativa do ar foram incluídas na amostra com suas médias anuais, acompanhadas de seus respectivos desvios padrões.

Compõem o conjunto de variáveis selecionadas para este estudo, no período entre 1999 e 2002:

- a) temperatura média anual e respectivo desvio padrão;
- b) Umidade Relativa do Ar anual e respectivo desvio padrão;
- c) Produto Interno Bruto – PIB anual;
- d) população anual.

3.2 BASE DE DADOS

Os dados da amostra-piloto foram dispostos sob a forma de matriz, cuja ordem é 96×6 , ou seja, 24 municípios ao longo de quatro anos e seis variáveis de entrada, já mencionadas anteriormente.

Um conjunto completo de testes foi realizado com a amostra-piloto, com o propósito de verificar a adequação do modelo às variáveis.

Para a ampliação da amostra inicial, foi utilizado um estudo complementar, desenvolvido no Departamento de Geografia da Universidade Federal do Rio Grande do Sul, cuja metodologia e mapa climatológico do Rio Grande do Sul encontram-se nos Anexo I e II.

A amostra passou de 24 para 144 municípios. Entretanto, 19 foram retirados da amostra final por não apresentarem dados para todas as seis variáveis deste estudo no período entre 1999 e 2002.

A base de dados definitiva – Anexo III – está organizada em forma de matriz, cuja ordem é 500×6 , ou seja, 125 municípios no período entre 1999 e 2002 ($125 \times 4 = 500$), e as seis variáveis de entrada mencionadas na seção anterior.

3.3 ESQUEMA GERAL PROPOSTO

De acordo com as premissas já enumeradas, foi definido, para o presente estudo, o seguinte esquema para a análise comparativa entre os modelos paramétrico e RNA (Figura 11 (a)) e para o estabelecimento de testes do modelo baseado em RNA (Figura 11 (b)).

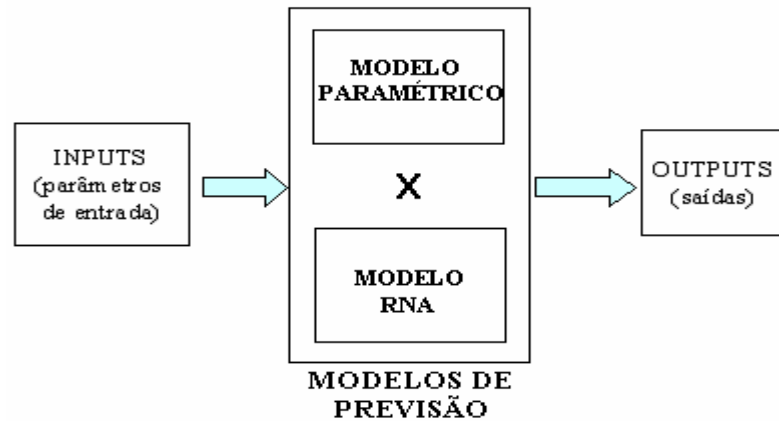


Figura 11 (a) – Esquema de estimativa comparativo REGRESSÃO \times RNA

Fonte: Elaborado pelo autor.

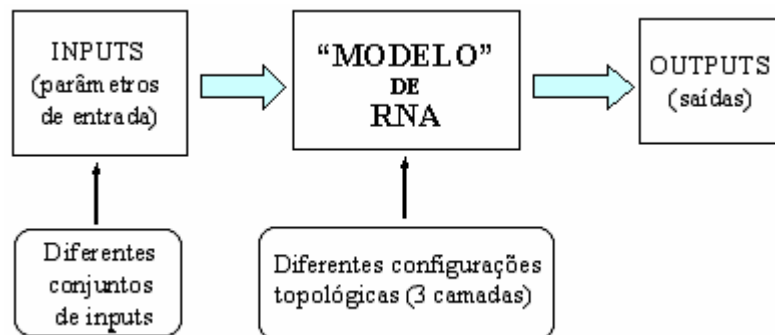


Figura 11 (b) – Esquema para testes da RNA.

Fonte: Elaborado pelo autor.

3.4 MODELOS UTILIZADOS NESTE ESTUDO

O modelo baseado em Redes Neurais Artificiais (Perceptron Multicamadas com Retropropagação de Erro) foi desenvolvido com o auxílio do software *MATLAB*, através de sua *Toolkit Neural Nets* (Biblioteca para Redes Neurais), dada a simplificação que tal ferramenta apresenta na manipulação de matrizes e vetores.

O modelo paramétrico foi desenvolvido pelo método estatístico dos mínimos quadrados, com o auxílio do software *Statistical Package for Social Sciences - SPSS*.

Os modelos foram testados com o mesmo conjunto de dados, utilizando-se 75% dos dados para o desenvolvimento de cada modelo e os 25% restantes para as previsões a serem calculadas (estimadas) para cada modelo. Em outras palavras, foram utilizados os dados no período de 1999 a 2001 no conjunto de treinamento e os dados do ano de 2002 foram utilizados no vetor de estimativas.

3.4.1 Modelo I

Rede Neural Artificial (perceptron) de Múltiplas Camadas com Algoritmo de Retropropagação do Erro.

Este tipo de rede tem sido amplamente utilizado em modelos de previsão de demanda (KERMANSHAHI, 1998; HOBBS *et al.*, 1998; SETYAWATI; CREESE; SAHIRMAN, 2003; SHARMA; KAMATH; TULUCA, 2003).

Conforme já visto em seções anteriores, basicamente, a aprendizagem por retropropagação de erro consiste de dois passos através das diferentes camadas da rede: um passo à frente, a propagação, e um passo para trás, a retropropagação. No passo para a frente, um padrão de atividade (vetor de entrada) é aplicado aos nós sensoriais da rede, e seu efeito se propaga através da rede, camada por camada. Um conjunto de saídas é fornecido como a resposta real da rede. Durante o passo de propagação, os pesos sinápticos da rede são todos fixos. Durante o passo para trás, os pesos sinápticos são todos ajustados de acordo com uma regra de correção do erro. Especificamente, a resposta real da rede é subtraída de uma resposta desejada (alvo) para produzir um sinal de erro. Este sinal de erro é propagado para trás através da rede, contra a direção das conexões sinápticas – vindo daí o nome de retropropagação de erro (*error backpropagation*). Os pesos sinápticos são ajustados para fazer com que a resposta da rede se mova para mais perto da resposta desejada, em um sentido estatístico, pela minimização da função de custo, conforme foi abordado na seção 2.1.6 (HAYKIN, 2001).

A Figura 12 seguir apresenta um diagrama em blocos da topologia adotada.




Figura 12 – Perceptron de múltiplas camadas com duas camadas ocultas

Fonte: *MATLAB* (2000)

Na Figura 12 acima, identificam-se os seguintes blocos:

- a) Vetor de entrada, no qual o algarismo 6 representa o número de variáveis de entrada.
- b) Matrizes de pesos, indicadas por $IW\{x, y\}$ para a camada de entrada da rede e por $LW\{x, y\}$, para as camadas ocultas, onde x representa o destino e y representa a origem da conexão.
- c) $b\{z\}$ representa o vetor de bias, e z refere-se à respectiva camada.
- d) Blocos de neurônios, cada qual com a indicação do respectivo número de neurônios e sua função de ativação.

3.4.2 Modelo II

O modelo regressivo, desenvolvido por meio de técnicas estatísticas de ajuste para uma distribuição multivariada de dados, tem por objetivo testar, de modo comparativo, a precisão do modelo baseado em redes neurais artificiais.

O mais popular dos modelos de previsão de demanda de energia elétrica, ajustado por técnicas de regressão estatística, é o modelo Auto-Regressivo Integrado Média-Móvel Sazonal (*ARIMA*) de Box-Jenkins. A estratégia para a construção do modelo, cuja estrutura se baseia nos próprios dados em um ciclo iterativo, usa técnicas estatísticas para o tratamento destes dados. Este modelo tornou-se amplamente popular, a partir do final da década de 70, e, ainda hoje é usado, devido ao fato de fornecer, com certa precisão, o comportamento do

processo estocástico que gerou a série temporal em estudo e, posteriormente gerar previsões de valores futuros para a série (SCHUCH, 1988).

Neste estudo, não foi possível ajustar o modelo *ARIMA* aos dados da amostra, posto que tais dados são de curta temporalidade. Deste modo, foi estabelecido um modelo regressivo linear multivariado utilizando a técnica estatística dos mínimos quadrados, com o auxílio do software *SPSS*.

4 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

Com o propósito de verificar a precisão e adequabilidade do modelo desenvolvido por redes neurais artificiais para a previsão de demanda de energia elétrica nos setores residencial, comercial e industrial, foi desenvolvido um conjunto completo de testes, em cinco seções, a saber:

- a) comparação do modelo desenvolvido por rede neural artificial com um modelo tradicional desenvolvido por meio de regressão linear multivariada. Como fator de comparação, foi usado o Desvio Padrão Residual (DPR), calculado a partir do Erro Médio Quadrático (EQM) para cada rede neural e para seu respectivo modelo regressional comparativo;
- b) testes para as variáveis de entrada das redes neurais nos setores estudados: Residencial, Comercial e Industrial, buscando-se verificar o peso de cada variável para a saída de cada rede;
- c) variações nas topologias das redes neurais, com a inclusão ou retirada de neurônios de suas camadas intermediárias;
- d) aleatorização nos dados de entrada das redes, com o propósito de verificar o peso da temporalidade dos dados de entrada na saída das redes neurais;
- e) regionalização do modelo: criação de três modelos distintos para o Estado do Rio Grande do Sul – (1) Região Norte, (2) Região Centro-Oeste e (3) Região Sul, Litoral e Porto Alegre, para a verificação do potencial da predição de demanda de energia elétrica de cada região para os setores estudados.

4.1 RNA *versus* REGRESSÃO

Nesta seção será feito o estudo comparativo do modelo baseado em rede neural artificial com um modelo desenvolvido pela técnica estatística da regressão linear

multivariada, iniciando-se pela apresentação e desenvolvimento das equações dos respectivos modelos.

4.1.1 Regressão Linear Multivariada

Para a determinação do modelo regressional, foram estabelecidas duas amostras, com, respectivamente, $n = 375$, e $n = 372$ observações – representando 75% dos dados de entrada, entre 1999 e 2001 – sendo que a segunda amostra exclui o município de Porto Alegre, a fim de verificar sua condição de *outlier* dentro do modelo.

Fórmula geral do modelo de regressão linear multivariada:

$$Y_{REG} = C_0 + C_1 X_1 + C_2 X_2 + C_3 X_3 + C_4 X_4 + C_5 X_5 + C_6 X_6 \quad (4.1)$$

onde:

Y_{REG} representa a demanda estimada de energia elétrica;

$C_0, C_1, C_2, C_3, C_4, C_5, C_6$ são as constantes;

$X_1, X_2, X_3, X_4, X_5, X_6$ representam, respectivamente, as variáveis temperatura, desvio padrão da temperatura, umidade relativa do ar, desvio padrão da umidade relativa do ar, PIB e população. Todas as variáveis de entrada têm referência anual.

O ajustamento foi determinado com o auxílio do software *SPSS*, com o cálculo das constantes de cada modelo. O teste de hipóteses correspondente – teste t de *Student* – verificou a significância de cada variável dentro do modelo de regressão. O teste de Snedecor-Fischer (análise de variância) mostra que, em se tratando de regressão linear multivariada, todos os modelos apresentados nas tabelas a seguir são válidos para as generalizações.

Sem o município Porto Alegre na amostra:

Tabela 1 – Coeficientes e níveis de significância do modelo regressional.

Setor	C ₀	C ₁	C ₂	C ₃	C ₄	C ₅	C ₆
RES	-27443,3	-1,1425	0,4096	0,4374	0,2584	1,85E-05	0,6807
Sig.	0,32	0,10	0,43	0,14	0,78	0,00	0,00
COML	-22714,06	-1,7455	-0,1782	0,4549	0,8344	2,25E-05	0,4997
Sig.	0,59	0,09	0,82	0,31	0,55	0,00	0,00
IND	-403732,6	7,4193	1,0861	3,6048	1,6704	0,0002	-0,8132
Sig.	0,00	0,03	0,67	0,01	0,71	0,00	0,00

Fonte: Elaborado pelo autor.

Com o município Porto Alegre na amostra:

Tabela 2 – Coeficientes e níveis de significância do modelo regressional.

Setor	C ₀	C ₁	C ₂	C ₃	C ₄	C ₅	C ₆
RES	-15112,13	-0,4932	0,6916	0,2449	-0,2329	1,46E-05	0,5040
Sig.	0,31	0,19	0,02	0,13	0,64	0,00	0,00
COML	1923,76	-0,7482	0,3701	0,1067	-0,0212	1,71E-05	0,1866
Sig.	0,59	0,09	0,82	0,31	0,54	0,00	0,00
IND	-423726,8	6,1828	0,6470	3,9399	2,5841	0,0002	-0,5128
Sig.	0,00	0,06	0,79	0,01	0,55	0,00	0,00

Fonte: Elaborado pelo autor.

Com o conjunto de dados referentes ao ano de 2002, foram determinados dois vetores para as predições para cada setor de demanda, com e sem o *outlier*.

4.1.2 Rede neural artificial

A rede neural, como já foi dito em seções precedentes, comporta-se como uma caixa-preta, isto é, não se tem acesso a detalhes internos de seu funcionamento. Conforme Beer (1979), a análise de um sistema “caixa-preta” é feita por meio de estímulos aplicados a sua

entrada (*input*), e, por meio da análise da saída (*output*) busca-se obter informações acerca de seu funcionamento interno.

O perceptron multicamadas com retropropagação de erro utilizado neste estudo é representado, conforme diagrama de blocos da Figura 12, por sua entrada, seus pesos, *bias*, funções de ativação, número de neurônios de cada camada e saída.

Os vetores de entrada são representados pelas respectivas variáveis de entrada: temperatura, desvio padrão da temperatura, umidade relativa do ar, desvio padrão da umidade relativa do ar, PIB e população de cada município da amostra para o período entre 1999 e 2001 formando a base de dados de treinamento, ficando os dados relativos ao ano de 2002 para estabelecer as estimativas. Os vetores de supervisão são representados pelas demandas de energia elétrica em cada setor: residencial, comercial e industrial.

Os dados acima mencionados sofreram uma transformação (normalização) prévia para um intervalo [-1, 1], conforme a seguinte equação:

$$x = 2 \frac{P - P_{\min}}{P_{\max} - P_{\min}} - 1 \quad (4.2)$$

onde:

P_{\min} é o valor mínimo do vetor;

P_{\max} é o valor máximo do vetor;

P é o valor do vetor a ser normalizado;

x é o elemento do vetor normalizado.

O exemplo apresentado a seguir tem o propósito meramente ilustrativo dos procedimentos adotados com as redes neurais utilizadas neste estudo.

Embora seja considerada na literatura pertinente como uma caixa-preta, a rede neural pode ter sua função de predição determinada, a exemplo do que foi feito com a regressão linear multivariada (equação 4.1). As matrizes de pesos sinápticos e *bias* são fornecidas pelo software *MATLAB* a cada conjunto de treinamento da rede.

A função de predição da rede neural mostrada na Figura 12 é dada por:

$$Y_{RNA} = \sum_{k=1}^{15} w_{1k} \cdot \mathbf{j} \left(\sum_{j=1}^5 w_{kj} \cdot \mathbf{j} \left(\sum_{i=1}^6 w_{ji} \cdot e_i + b_j \right) + b_k \right) + b_1 \quad (4.3)$$

onde:

Y_{RNA} representa a demanda estimada de energia elétrica;

e_i representa a entrada da rede (vetor de variáveis de entrada);

w_{ji} , w_{kj} e w_{1k} representam os pesos sinápticos das respectivas camadas da rede neural;

b_1 , b_j e b_k representam os *bias* das respectivas camadas da rede neural.

j , já definida anteriormente, é a função de ativação que determina a saída do neurônio.

A função de ativação φ , usada nas duas camadas ocultas deste estudo é definida pela seguinte equação:

$$Y_i = \frac{2}{1 + \exp(-2X_i)} - 1 \quad (4.4)$$

onde

$i = 1, 2, \dots, n$, com n representando o número de municípios da amostra;

X_i é o vetor de entrada da respectiva camada, que será detalhado mais adiante; e

Y_i é o vetor de saída da respectiva camada.

A camada de saída utiliza uma função linear simples, isto é, constituída pela própria saída do combinador linear do neurônio de saída, visto que o neurônio de saída não necessita ser ativado por uma função diferenciável (logística), que é considerada como mais apropriada ao algoritmo de minimização do erro para o ajuste dos pesos sinápticos, conforme foi tratado na seção 2.1.6.

Para o setor comercial, as matrizes de pesos sinápticos e *bias* de um exemplo de treinamento foram as seguintes:

$$IW(1,1) = \begin{bmatrix} 1,233 & 1,295 & -1,724 & -1,181 & 1,051 & -1,001 \\ -0,708 & 0,523 & 2,106 & 1,512 & -0,723 & -0,432 \\ 0,062 & 0,029 & 0,427 & 0,537 & 1,369 & -1,928 \\ 0,445 & 2,556 & 0,724 & 0,469 & -0,730 & -0,629 \\ 0,248 & -0,361 & -0,260 & 0,169 & 2,350 & 2,011 \end{bmatrix}$$

$IW(1,1)$ é a matriz que contém os pesos sinápticos da primeira camada oculta relativamente à entrada da rede neural.

$$LW(2,1) = \begin{bmatrix} -1,296 & 0,595 & 0,930 & 0,923 & -0,539 \\ 0,313 & 0,733 & -0,092 & -0,908 & 1,455 \\ 0,164 & 1,514 & -0,602 & 1,257 & -0,433 \\ 0,491 & 0,067 & -0,012 & -0,456 & -0,552 \\ -0,738 & 0,165 & -0,731 & -0,194 & 0,268 \\ -1,078 & -1,036 & -0,071 & -1,062 & -0,625 \\ 0,898 & -0,739 & 0,471 & -0,402 & -1,103 \\ 0,482 & -0,468 & -0,666 & -0,427 & 0,060 \\ 1,116 & 1,108 & 0,964 & 0,290 & -0,279 \\ 0,133 & -0,640 & 0,647 & -0,805 & -0,731 \\ -1,214 & 1,659 & -0,569 & 0,659 & 1,257 \\ -1,031 & -0,073 & 1,049 & 0,558 & -1,068 \\ -0,177 & -0,312 & -1,229 & -0,352 & 1,056 \\ -0,595 & -1,665 & 0,418 & -1,018 & 1,570 \\ -0,370 & -0,642 & 0,087 & -0,969 & 1,800 \end{bmatrix}$$

$LW(2,1)$ é a matriz que contém os pesos sinápticos da segunda camada oculta relativamente à primeira camada oculta da rede neural.

$$LW(3,2)^T = \begin{bmatrix} -0,592 \\ 1,001 \\ -1,071 \\ -0,843 \\ 1,308 \\ 0,431 \\ 1,144 \\ 1,406 \\ 1,402 \\ -1,200 \\ 0,413 \\ 0,904 \\ 0,920 \\ -0,927 \\ -0,867 \end{bmatrix}$$

$LW(3,2)$ é a matriz que contém os pesos sinápticos da camada de saída, relativamente à segunda camada oculta da rede neural, apresentada acima na sua forma transposta por mera questão de espaço.

$$B_1 = \begin{bmatrix} 1,426 \\ 0,170 \\ -0,242 \\ 1,187 \\ 3,294 \end{bmatrix}$$

B_1 é a matriz que contém os *bias* da primeira camada oculta da rede neural.

$$B_2 = \begin{bmatrix} -0,510 \\ -0,283 \\ 0,209 \\ -0,312 \\ -0,359 \\ -0,365 \\ -0,324 \\ -1,114 \\ -0,454 \\ -1,027 \\ 0,008 \\ -0,301 \\ 0,244 \\ -0,366 \\ 0,677 \end{bmatrix}$$

B_2 é a matriz que contém os *bias* da segunda camada oculta da rede neural.

$$B_3 = [0,062]$$

B_3 é a matriz que contém os *bias* da camada de saída da rede neural.

A matriz E_r contém os dados usados no cálculo da estimação, cujo formato é 125×6 , onde $r = 1, 2, \dots, 125$, representa seus respectivos vetores.

Tomando-se o primeiro vetor da matriz E_r , pode-se escrever a seqüência de cálculos que determinará o vetor de saída da rede neural, conforme demonstrado a seguir:

$$E_1 = \begin{bmatrix} -0,286 \\ -0,861 \\ 0,133 \\ -0,359 \\ -0,944 \\ -0,834 \end{bmatrix} \begin{array}{l} \leftarrow \text{temperatura normalizada} \\ \leftarrow \text{desvio padrão da temperatura normalizado} \\ \leftarrow \text{umidade relativa do ar normalizada} \\ \leftarrow \text{desvio padrão da umidade relativa do ar normalizado} \\ \leftarrow \text{PIB normalizado} \\ \leftarrow \text{população normalizada} \end{array}$$

E_1 é o vetor que contém o primeiro conjunto de dados de entrada da rede neural.

Com as matrizes apresentadas neste exemplo e de acordo com a função definida na equação (4.3) foi realizada a seqüência de cálculos a seguir:

a) $IW(1,1) \times E_1 \rightarrow$ produto da matriz de pesos da primeira camada oculta da rede neural pelo primeiro vetor de entrada (matriz E_r);

b) $X_1 = IW(1,1) \times E_1 + B_1 \rightarrow$ soma do vetor de *bias* da primeira camada oculta da rede neural;

c) $Y_1 = \frac{2}{1 + \exp(-2X_1)} - 1 \rightarrow$ calcula o vetor de saída da primeira camada oculta da rede neural para o primeiro vetor de entrada;

d) $LW(2,1) \times Y_1 \rightarrow$ produto da matriz de pesos da segunda camada oculta da rede neural pelo primeiro vetor de saída da primeira camada oculta da rede neural;

e) $X_2 = LW(2,1) \times Y_1 + B_2 \rightarrow$ soma do vetor de *bias* da segunda camada oculta da rede neural;

f) $Y_2 = \frac{2}{1 + \exp(-2X_2)} - 1$ calcula o vetor de saída da segunda camada oculta da rede neural;

g) $LW(3,2) \times Y_2 \rightarrow$ produto da matriz de pesos da camada de saída da rede neural pelo vetor de saída da segunda camada oculta da rede neural;

h) $X_3 = LW(3,2) \times Y_2 + B_3 \rightarrow$ soma do vetor de *bias* da camada de saída da rede neural;

i) $Y_3 = X_3 \rightarrow$ saída da rede neural para o primeiro vetor de entrada E_1 .

Os passos definidos acima foram realizados de forma recursiva para todos os demais vetores de entrada da matriz E_r , determinando-se, desta forma, a estimativa de demanda de

energia elétrica do setor correspondente. Os resultados obtidos pela seqüência de cálculos indicada acima apresentam divergência inferior a 1%, quando comparados com aqueles determinados diretamente pela rede neural artificial, isto é, do algoritmo implementado através do software MATLAB. Os erros verificados podem ser atribuídos ao truncamento e a conseqüente propagação de erro, dada a grande quantidade de cálculos envolvidos.

4.1.3 Comparação entre os Modelos

Com as predições determinadas pela RNA e pela equação de regressão, foi estabelecida uma comparação entre os modelos, tomando-se como parâmetro o Desvio Padrão Residual (DPR), que foi calculado a partir do Erro Quadrado Médio (EQM), conforme as equações 4.5 e 4.6.

$$EQM = \frac{\sum_{i=1}^n (R_i - D_i)^2}{n} \quad (4.5)$$

onde

R_i é o valor estimado na saída da rede para o município i .

D_i é a demanda conhecida do município i .

n é o número de municípios que compõem a amostra.

O Desvio Padrão Residual (DPR) é dado por

$$DPR = \sqrt{EQM} \quad (4.6)$$

É preciso ressaltar que o erro calculado pela equação (4.6) acima é um erro associado à estimativa, e que difere daquele calculado pela equação (2.9). Este, por sua vez, se relaciona com a diferença entre a saída desejada e a saída fornecida pela rede para cada neurônio da camada de saída em cada iteração do algoritmo de retropropagação de erro, durante a fase de treinamento da rede.

Há várias maneiras de se calcular a acurácia da previsão, dentre elas, o erro percentual absoluto médio. Entretanto, segundo Wheelwright & Makridakis (1985), não há um critério

de consenso absoluto entre os autores sobre qual é a melhor forma de se analisar a acurácia de uma previsão.

Para os propósitos deste estudo, levou-se em conta a grande variabilidade dos dados da amostra, que levava a erros percentuais também elevados e optou-se por adotar o Desvio Padrão Residual como critério básico para a análise dos resultados.

Duas seções de testes foram realizadas com o propósito de determinar a condição de *outlier* do município de Porto Alegre. Os resultados estão apresentados nas Tabelas 4 e 5, a seguir.

Sem o município de Porto Alegre na amostra:

Tabela 3 – Comparação entre os modelos.

	RNA	REGRESSÃO
SETOR	DPR	DPR
RESIDENCIAL	5,7021E + 03	6,2529E + 05
COMERCIAL	5,0265E + 03	2,3460E + 04
INDUSTRIAL	6,7234E + 04	1,2523E + 05

Fonte: Elaborado pelo autor.

Os DPRs nas previsões de demandas residencial, comercial e industrial foram, respectivamente, cerca de 110 vezes, 5 vezes e 2 vezes superiores no modelo regressional em relação ao modelo baseado em RNA.

Com o município de Porto Alegre na amostra:

Tabela 4 – Comparação entre os modelos.

	RNA	REGRESSÃO
SETOR	DPR	DPR
RESIDENCIAL	6,8041E + 03	8,5112E + 05
COMERCIAL	6,1689E + 03	6,8040E + 05
INDUSTRIAL	7,8883E + 04	6,7055E + 05

Fonte: Elaborado pelo autor.

Os DPRs nas previsões de demandas residencial, comercial e industrial foram, respectivamente, 125 vezes, 110 vezes e 9 vezes superiores no modelo regressional em relação ao modelo desenvolvido em RNA.

As Figuras 13, 14 e 15, a seguir, trazem os gráficos comparativos para os dois modelos – RNA e regressão – para os três setores de demanda supramencionados.




Figura 13 – Estimativa de demanda residencial.

Fonte: Elaborado pelo autor.

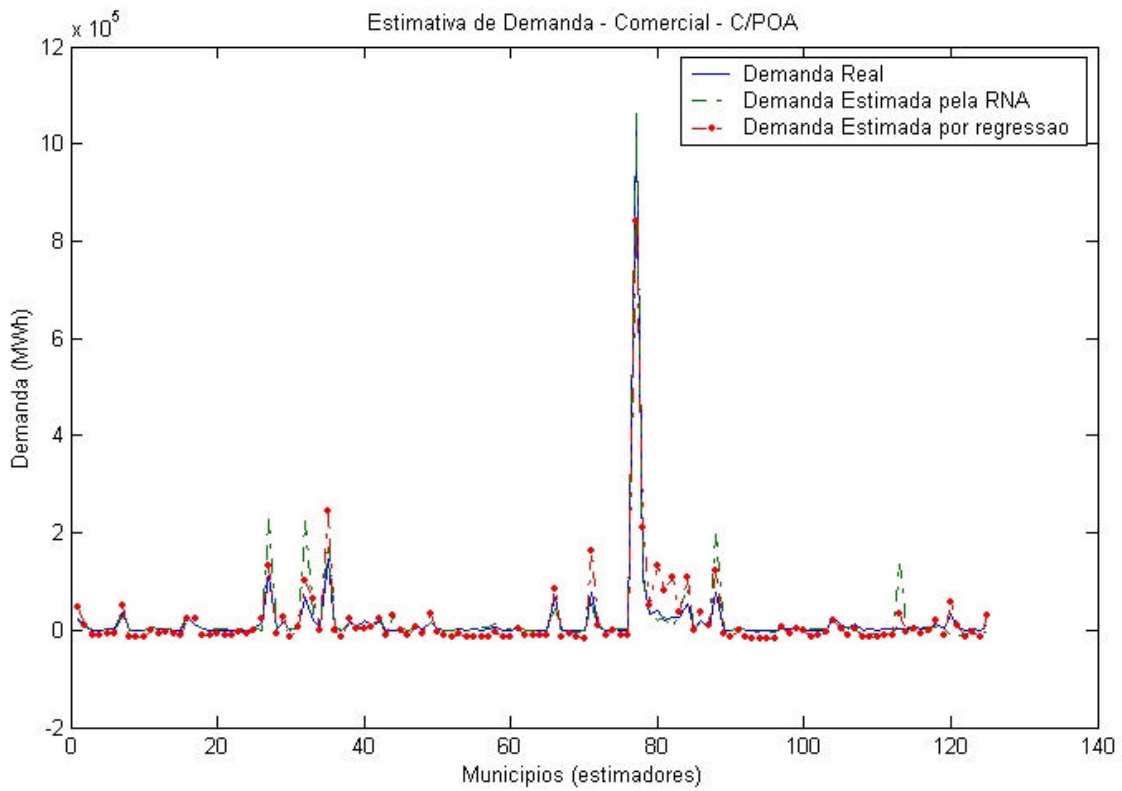


Figura 14 – Estimativa de demanda comercial.

Fonte: Elaborado pelo autor.




Figura 15 – Estimativa de demanda industrial.

Fonte: Elaborado pelo autor.

Comparando-se os resultados dos dois conjuntos de testes entre os modelos, com e sem o município de Porto Alegre na amostra, foi claramente verificado que este município se constitui em um *outlier*. Os DPRs de ambos os modelos, em todos os setores, são maiores quanto se inclui o município de Porto Alegre na amostra, conforme ficou evidenciado nas Tabelas 3 e 4 e na correspondente análise comparativa entre os resultados. Além disto, ainda que a rede neural possa ser afetada por *outliers*, foi evidenciado nesta uma capacidade superior ao modelo paramétrico, durante o trato de séries de dados com *outliers*.

4.2 TESTES DE VARIÁVEIS DE ENTRADA

Setyawati, Creese e Sahirman (2003) destacam, entre outros fatores, a seleção das variáveis de entrada, bem como a quantidade de variáveis, como apresentando grande importância na modelagem do problema por meio de redes neurais artificiais. Não é recomendável o desenvolvimento de redes neurais com uma quantidade pequena – em geral, inferior a três – de variáveis de entrada.

Neste conjunto de testes, foi realizada a retirada sistemática, do conjunto de entrada da rede neural, de cada uma das variáveis utilizadas no estudo, com o propósito de determinar o peso exercido por estas nos resultados de generalização da rede.

A análise realizada é marginal, na medida em que uma única variável é retirada de cada vez, mantendo-se a arquitetura da rede. Uma análise mais aprofundada, variando-se inclusive a topologia da rede neural foge ao escopo desta dissertação.

4.2.1 Modelo RNA – S/TEMP

Com a retirada da variável “temperatura” e de seu respectivo desvio padrão do conjunto das variáveis de entrada, o modelo baseado em RNA apresentou os seguintes resultados para os respectivos DPRs:

Tabela 5 – Efeitos da retirada da variável temperatura e do seu respectivo desvio padrão do vetor de entrada da rede neural.

Setor	Com temperatura	Sem temperatura	D%
RESIDENCIAL	6,8041E + 03	8,0453E + 04	+1082%
COMERCIAL	6,1689E + 03	1,0391E + 05	+1584%
INDUSTRIAL	7,8883E + 04	6,8735E + 04	+15%

Fonte: Elaborado pelo autor.

Variações significativas ficaram evidentes nos setores residencial e comercial, constatação esta que aponta para um alto impacto da variável temperatura na predição de demanda de energia elétrica nos setores mencionados. Com efeito, a variável temperatura ambiente foi apontada por Bolzern e Fronza (1986) como um forte indicador de demanda de energia elétrica.

4.2.2 Modelo RNA – S/URA

Retirando-se a variável umidade relativa do ar e seu respectivo desvio padrão dos parâmetros de entrada, a RNA apresentou os seguintes resultados comparativos de DPRs:

Tabela 6 – Efeitos da retirada da variável umidade relativa do ar e do seu respectivo desvio padrão do vetor de entrada da rede neural.

Setor	Com umidade relativa do ar	Sem umidade relativa do ar	D%
RESIDENCIAL	6,8041E + 03	7,3389E + 04	+979%
COMERCIAL	6,1689E + 03	3,3958E + 04	+450%
INDUSTRIAL	7,8883E + 04	9,7500E + 04	+24%

Fonte: Elaborado pelo autor.

A variável umidade relativa do ar surge como um forte preditor de demanda residencial e comercial de energia elétrica, uma vez que, juntamente com a temperatura ambiente, transmite o efeito de sensação térmica sobre o organismo humano.

Os resultados obtidos nas duas seções precedentes confirmam que a sensação térmica – determinada pelo binômio: temperatura umidade do ar – é fator preponderante das

demandas residencial e comercial. Um exemplo prático do efeito da sensação térmica, ou temperatura virtual sobre o organismo humano é verificado em dias demasiadamente quentes do verão, nos quais são registrados picos de consumo de energia elétrica pelas concessionárias do setor.

4.2.3 Modelo RNA – S/PIB

Retirando-se a variável PIB dos parâmetros de entrada, a RNA apresentou o seguinte quadro comparativo:

Tabela 7 – Efeitos da retirada da variável PIB do vetor de entrada da rede neural.

Setor	Com PIB	Sem PIB	D%
RESIDENCIAL	6,8041E + 03	4,6899E + 04	+589%
COMERCIAL	6,1689E + 03	5,6500E + 04	+816%
INDUSTRIAL	7,8883E + 04	8,4208E + 05	+968%

Fonte: Elaborado pelo autor.

A retirada da variável PIB causou impacto sobre todas as demandas de energia elétrica deste estudo, com aumentos consideráveis sobre os respectivos erros de predição. A riqueza dos municípios da amostra – medidas pelo PIB – está diretamente relacionada com a demanda de energia elétrica dos mesmos.

4.2.4 Modelo RNA – S/POP

Retirando-se a variável população dos parâmetros de entrada, a RNA apresentou o seguinte quadro comparativo:

Tabela 8 – Efeitos da retirada da variável população do vetor de entrada da rede neural.

Setor	Com população	Sem população	D%
RESIDENCIAL	6,8041E + 03	1,1097E + 05	+1531%
COMERCIAL	6,1689E + 03	9,5854E + 04	+1454%
INDUSTRIAL	7,8883E + 04	1,0816E + 05	+37%

Fonte: Elaborado pelo autor.

A densidade demográfica causa impacto nas estimativas de demanda de energia elétrica residencial e comercial.

4.3 VARIAÇÕES TOPOLÓGICAS NA REDE

Segundo Braga, Carvalho e Ludermir (2000), as redes neurais implementadas com o algoritmo de *backpropagation* – e ainda outros tipos de redes neurais artificiais – são vistas como “caixas pretas”, visto que não se sabe porque a rede chega a um determinado resultado. As pesquisas tendem a buscar procedimentos explicativos que justifiquem o comportamento da rede em determinadas situações. Sabe-se, por exemplo, que o tempo de processamento está ligado ao tamanho da rede.

Ainda conforme Braga, Carvalho e Ludermir (2000), uma rede com duas camadas ocultas pode aproximar qualquer função matemática, além de facilitar o treinamento da mesma. Entretanto, redes com várias camadas intermediárias não são recomendadas, pois cada vez que o erro medido durante o treinamento é propagado para a camada anterior, esta se torna menos precisa. O número de neurônios em cada camada é, em geral, definido empiricamente. Alguns métodos sugerem – sem generalizações – que o número de neurônios deve ser definido em função do número de entradas e saídas, ou, ainda, que este número deva ser em torno de dez por cento do número de exemplos de treinamento.

Braga, Carvalho e Ludermir. (2000), salientam, ainda, o cuidado que se deve ter para não usar neurônios em demasia, visto que, neste caso, a rede poderá memorizar seus próprios padrões de treinamento em lugar de estabelecer generalizações adequadas com dados não vistos durante o treinamento; e também não se pode usar um número muito pequeno de

unidades, que pode levar a rede à sobrecarga, com a perda da capacidade de generalizar ou de encontrar uma solução ótima.

Em resumo, o número de neurônios das camadas ocultas depende dos seguintes fatores:

- a) número de exemplos de treinamento;
- b) quantidade de ruído presente nos exemplos;
- c) complexidade da função a ser aprendida; e
- d) distribuição estatística dos dados de treinamento.

Para Setyawati, Creese e Sahirman, (2003) é muito difícil definir a arquitetura (topologia) ideal da rede. De modo empírico, foi determinado que a precisão obtida e a implementação de uma rede perceptron dependem do número de nodos utilizados nas camadas intermediárias, bem como da definição da função de ativação.

Baseado nestas considerações, foram feitas algumas variações topológicas nas camadas intermediárias da rede neural implementada neste estudo para a verificação dos efeitos que tais variações exercem sobre o modelo proposto. Os resultados são apresentados a seguir.

Tabela 9 – Variações topológicas da rede.

SETOR	Rede padrão	Variação topológica	
	$5 \times 15 \times 1$	$4 \times 15 \times 1$	D%
RESIDENCIAL	6,8041E + 03	6,8970E + 03	+1%
COMERCIAL	6,1689E + 03	7,5600E + 03	+23%
INDUSTRIAL	7,8883E + 04	1,6942E + 05	+115%

SETOR	Rede padrão	Variação topológica	
	$5 \times 15 \times 1$	$3 \times 15 \times 1$	D%
RESIDENCIAL	6,8041E + 03	6,9010E + 03	+1%
COMERCIAL	6,1689E + 03	6,7610E + 03	+10%
INDUSTRIAL	7,8883E + 04	9,9239E + 04	+26%

SETOR	Rede padrão	Variação topológica	D%
	5×15×1	2×15×1	
RESIDENCIAL	6,8041E + 03	6,9270E + 03	+1%
COMERCIAL	6,1689E + 03	7,9080E + 03	+28%
INDUSTRIAL	7,8883E + 04	2,6937E + 05	+241%

SETOR	Rede padrão	Variação topológica	D%
	5×15×1	5×12×1	
RESIDENCIAL	6,8041E + 03	1,0128E + 03	+49%
COMERCIAL	6,1689E + 03	7,3600E + 03	+19%
INDUSTRIAL	7,8883E + 04	9,7909E + 04	+24%

SETOR	Rede padrão	Variação topológica	D%
	5×15×1	5×11×1	
RESIDENCIAL	6,8041E + 03	7,8800E + 03	+16%
COMERCIAL	6,1689E + 03	7,6940E + 03	+25%
INDUSTRIAL	7,8883E + 04	9,6567E + 04	+22%

SETOR	Rede padrão	Variação topológica	D%
	5×15×1	5×10×1	
RESIDENCIAL	6,8041E + 03	8,7000E + 03	+28%
COMERCIAL	6,1689E + 03	1,2432E + 04	+102%
INDUSTRIAL	7,8883E + 04	1,6997E + 05	+115%

Continua...

Continuação.

SETOR	Rede padrão	Varição topológica	D%
	$5 \times 15 \times 1$	$3 \times 13 \times 1$	
RESIDENCIAL	6,8041E + 03	6,8754E + 03	+1%
COMERCIAL	6,1689E + 03	6,2280E + 03	+1%
INDUSTRIAL	7,8883E + 04	8,2835E + 04	+5%

SETOR	Rede padrão	Varição topológica	D%
	$5 \times 15 \times 1$	$5 \times 20 \times 1$	
RESIDENCIAL	6,8041E + 03	7,1890E + 03	+6%
COMERCIAL	6,1689E + 03	8,0730E + 03	+31%
INDUSTRIAL	7,8883E + 04	1,5969E + 05	+102%

SETOR	Rede padrão	Varição topológica	D%
	$5 \times 15 \times 1$	$5 \times 25 \times 1$	
RESIDENCIAL	6,8041E + 03	9,2700E + 03	+36%
COMERCIAL	6,1689E + 03	1,0410E + 04	+69%
INDUSTRIAL	7,8883E + 04	2,5928E + 05	+161%

Fonte: Elaborado pelo autor.

A tabela acima apresenta os DPRs dos setores residencial, comercial e industrial para algumas variações topológicas na rede, com a retirada ou acréscimo de neurônios em suas camadas intermediárias. As topologias são identificadas pelo respectivo número de neurônios em cada camada.

Nas topologias $2 \times 15 \times 1$, $5 \times 12 \times 1$, $5 \times 10 \times 1$, $5 \times 20 \times 1$ e $5 \times 25 \times 1$, a rede não conseguiu estabelecer a correta relação entrada-saída e travou. Isto indica que, neste estudo, a quantidade de neurônios na primeira camada oculta não pode ser inferior a três. Na segunda camada oculta, a quantidade de neurônios não pode ser inferior a 13 nem muito superior a 15. Pelos resultados da tabela acima, verifica-se que a rede com topologia $3 \times 13 \times 1$ foi a que

apresentou resultados mais próximos da rede $5 \times 15 \times 1$, que foi a adotada como padrão pelo seu melhor desempenho, e, por esta razão, usada em todos os demais testes realizados neste estudo.

Em geral, a redução no número de neurônios nas camadas intermediárias da rede neural tende a acelerar o algoritmo de treinamento. Em contrapartida, o aumento do número de neurônios torna o algoritmo extremamente lento, corroborando com as considerações apresentadas anteriormente, que indicam que o tempo de processamento está ligado ao tamanho da rede (BRAGA; CARVALHO; LUDERMIR, 2000).

4.4 ALEATORIZAÇÃO NOS DADOS DE ENTRADA

Com o propósito de verificar se há viés nos resultados em virtude da ordem de apresentação dos dados à rede, foi realizada uma aleatorização controlada nos dados de entrada, na qual, para cada município da amostra, foram inseridos no conjunto de treinamento três períodos entre 1999 e 2002 de forma totalmente aleatória, ficando o período remanescente para a determinação das predições. O propósito deste conjunto de testes foi o de verificar o efeito da temporalidade – e da própria aleatorização, se houver – dos dados de entrada da RNA na sua relação entrada-saída.

O total de arranjos possíveis é de 125^4 . Deste universo, foram tomadas 30 amostras, selecionadas (sorteadas) com o auxílio da função “aleatório” do MS Excel, com valores no intervalo (0, 1). O critério para a formação das amostras foi tomar, para o vetor de predição, a ocorrência de cada município que apresentasse o menor valor no intervalo (0, 1) no período entre 1999 e 2002, conforme exemplifica a Tabela 10.

Tabela 10 – Exemplo da metodologia utilizada para construir as amostras aleatorizadas.

Município	Amostra 1	Amostra 2	Amostra 3	...	Amostra 30
Água Santa (1999)	0,5941	0,7158	0,8845	...	0,4059
Água Santa (2000)	0,1387	0,6449	0,0358	...	0,4779
Água Santa (2001)	0,7651	0,5664	0,3347	...	0,4757
Água Santa (2002)	0,8828	0,9283	0,5966	...	0,3106
Alegrete (1999)	0,9589	0,4964	0,1050	...	0,6245

Continua...

Continuação.

Alegrete (2000)	0,6130	0,3844	0,3642	...	0,0438
Alegrete (2001)	0,2706	0,8701	0,2820	...	0,6121
Alegrete (2002)	0,5867	0,4269	0,5472	...	0,4023
Alpestre (1999)	0,4244	0,8225	0,4253	...	0,8069
Alpestre (2000)	0,3995	0,8013	0,7827	...	0,5609
Alpestre (2001)	0,4922	0,7456	0,9843	...	0,7384
Alpestre (2002)	0,7140	0,4134	0,8704	...	0,2755
...

Fonte: Elaborado pelo autor.

Valores destacados em negrito indicam a ocorrência de cada município que comporá o vetor de supervisão para a predição, em cada uma das 30 amostras.

Para a verificação da equiprobabilidade dos sorteios que determinaram o vetor de estimação em cada amostra, foi realizado um teste de aderência de Kolmogorov-Smirnov (K-S), por meio do software *SPSS*, para a distribuição Uniforme.

Hipóteses do teste de aderência:

$$\begin{cases} H_0 : \text{Uniforme } (0, 1) \\ H_1 : \text{não - Uniforme} \end{cases}$$

Ao nível de significância, α , de 5% foi aceita a hipótese nula em 29 das 30 amostras, apontando, desta forma para a uniformidade da distribuição.

A fim de confirmar o resultado acima, também foi realizado o *run-up test*, que, segundo Law e Kelton (2000), consiste em um teste empírico mais direto para a verificação de independência entre valores de uma amostra gerada aleatoriamente. O teste consiste na realização de rodadas (*runs*) com sub-amostras de diversos tamanhos. Detalhes sobre o método podem ser encontrados em Law e Kelton (2000).

O resultado do *run-up test*, pelo software *SPSS*, foi não-significativo, isto é, foi aceita a hipótese de independência entre os valores em 29 das 30 amostras.

A tabela a seguir mostra os respectivos DPRs de cada teste e a variação percentual (VP) relativa ao modelo padrão, que utiliza o período entre 1999 e 2001 para o treinamento, e o ano de 2002 para a validação (estimativas).

Tabela 11 – DPRs e variações percentuais em relação à rede padrão de cada uma das 30 amostras aleatorizadas.

Amostra	Residencial		Comercial		Industrial	
	DPR = 6,8041E + 03		DPR = 6,1689E + 03		DPR = 7,8883E + 05	
	DPR	VP	DPR	VP	DPR	VP
1	4,15E + 03	-39%	4,13E + 03	-33%	1,81E + 05	-77%
2	5,10E + 03	-25%	5,92E + 03	-4%	3,08E + 05	-61%
3	7,08E + 03	+4%	5,61E + 03	-9%	6,07E + 05	-23%
4	4,01E + 03	-41%	6,05E + 03	-2%	1,50E + 05	-81%
5	3,95E + 03	-42%	4,94E + 03	-20%	2,37E + 05	-70%
6	4,01E + 03	-41%	5,49E + 03	-11%	1,18E + 05	-85%
7	4,42E + 03	-35%	5,68E + 03	-8%	1,03E + 05	-87%
8	4,76E + 03	-30%	5,49E + 03	-11%	1,97E + 05	-75%
9	4,83E + 03	-29%	5,86E + 03	-5%	1,81E + 05	-77%
10	5,58E + 03	-18%	6,05E + 03	-2%	2,37E + 05	-70%
11	4,22E + 03	-38%	5,86E + 03	-5%	2,45E + 05	-69%
12	5,24E + 03	-23%	8,20E + 03	+33%	1,42E + 05	-82%
13	1,05E + 04	+54%	8,14E + 03	+32%	1,97E + 05	-75%
14	4,35E + 03	-36%	6,11E + 03	-1%	1,26E + 05	-84%
15	5,72E + 03	-16%	9,38E + 03	+52%	1,50E + 05	-81%
16	5,99E + 03	-12%	7,71E + 03	+25%	1,89E + 05	-76%
17	5,78E + 03	-15%	5,92E + 03	-4%	1,89E + 05	-76%
18	6,60E + 03	-3%	8,76E + 03	+42%	4,02E + 05	-49%
19	4,15E + 03	-39%	6,85E + 03	+11%	3,94E + 05	-50%
20	6,80E + 03	0%	6,79E + 03	+10%	1,66E + 05	-79%
21	8,71E + 03	+28%	7,34E + 03	+19%	2,60E + 05	-67%
22	8,98E + 03	+32%	9,38E + 03	+52%	2,21E + 05	-72%
23	6,60E + 03	-3%	5,98E + 03	-3%	3,71E + 05	-53%
24	4,69E + 03	-31%	4,81E + 03	-22%	1,50E + 05	-81%
25	6,94E + 03	+2%	6,72E + 03	+9%	3,47E + 05	-56%
26	4,97E + 03	-27%	6,66E + 03	+8%	3,47E + 05	-56%
27	5,78E + 03	-15%	5,12E + 03	-17%	3,23E + 05	-59%
28	7,21E + 03	+6%	6,42E + 03	+4%	1,97E + 05	-75%
29	8,64E + 03	+27%	4,32E + 03	-30%	1,58E + 05	-80%
30	7,21E + 03	+6%	5,74E + 03	-7%	3,63E + 05	-54%
Média	5,90E + 03		6,38E + 03		2,42E + 05	
D. P.	1,70E + 03		1,36E + 03		1,12E + 05	

Fonte: Elaborado pelo autor.

Gráficos:




Gráfico 1 – Demanda residencial.

Fonte: SPSS




Gráfico 2 – Demanda comercial.

Fonte: SPSS




Gráfico 3 – Demanda industrial.

Fonte: SPSS

Verificou-se, para a distribuição da Tabela 11, a existência de normalidade, por meio do Teste de Kolmogorov-Smirnov para a Normal, com nível de significância de 5%, conforme descrito a seguir.

Hipóteses do Teste:

$$\begin{cases} H_0 : \text{é Normal} \\ H_1 : \text{não é Normal} \end{cases}$$

Resultados obtidos:

Setor	Residencial	Comercial	Industrial
Média (MWh)	5,90E + 03	6,38E + 03	2,42E + 05
Desvio Padrão (MWh)	1,70E + 03	1,36E + 03	1,12E + 05
Significância	0,73	0,33	0,29

Adotando-se o nível de significância padrão de 0,05 (5%) para os testes, aceita-se a existência de normalidade nos resultados, visto que os níveis de significâncias dos testes de hipóteses para os três setores, mostrados no quadro acima, são superiores a 0,05. É provável que a aleatorização nos dados de entrada não provoquem variações significativas na relação entrada-saída determinadas pela rede neural utilizada neste estudo.

4.5 REGIONALIZAÇÃO DO MODELO (RNA)

De acordo com o Balanço Energético Nacional (BRASIL. MINISTÉRIO DE MINAS E ENERGIA, 2004), a previsão do mercado de energia elétrica não é realizado de forma agregada, devido à dimensão continental do País, que provoca estruturas sócio-econômicas e disponibilidade de recursos energéticos bastante diferenciados entre as regiões. Deste modo, as previsões são feitas com o somatório das previsões das concessionárias de energia elétrica.

Ainda que este estudo tenha ficado restrito ao Estado do Rio Grande do Sul, existem características peculiares a cada região do Estado que podem causar impacto na previsão realizada por intermédio de um modelo único para todo o Estado. Além disto, há no Estado três concessionárias (distribuidoras) de energia elétrica.

Conforme Braga, Carvalho e Ludermir (2000), Haykin (2001) e vários outros autores, uma diversidade muito grande nos dados (ruído) pode levar a rede à perda da capacidade de generalização.

Levando-se em conta as considerações feitas anteriormente, a amostra inicial foi subdividida em três, com o propósito de abranger três grandes regiões do Rio Grande do Sul, com a aplicação do modelo baseado em RNA a cada uma destas regiões, conforme especificado a seguir.

4.5.1 Região Centro-Oeste

Amostra de tamanho $n_1 = 35$, com os seguintes municípios integrantes: Alegrete, Araricá, Arroio do Meio, Barra do Quaraí, Caçapava do Sul, Cachoeira do Sul, Campo Bom, Canoas, Colinas, Cruzeiro do Sul, Estância Velha, Esteio, Estrela, Formigueiro, Itaqui, Lajeado, Maçambará, Montenegro, Nova Santa Rita, Novo Hamburgo, Paverama, Portão, Quaraí, Restinga Seca, Santana do Livramento, Santa Maria, Santana da Boa Vista, Santo

Antônio das Missões, São Leopoldo, Sapiranga, Sapucaia do Sul, Taquari, Teutônia, Triunfo e Uruguaiana.

Os testes realizados com a topologia padrão (5×15×1) forneceram os resultados apresentados na tabela abaixo.

Tabela 12 – DPRs para a região Centro-Oeste

SETOR	DPR
RESIDENCIAL	3,8996E + 03
COMERCIAL	3,0299E + 03
INDUSTRIAL	2,4458E + 04

Fonte: Elaborado pelo autor.

As Figuras 16, 17 e 18 ilustram os resultados obtidos e mostram boa convergência nos resultados.

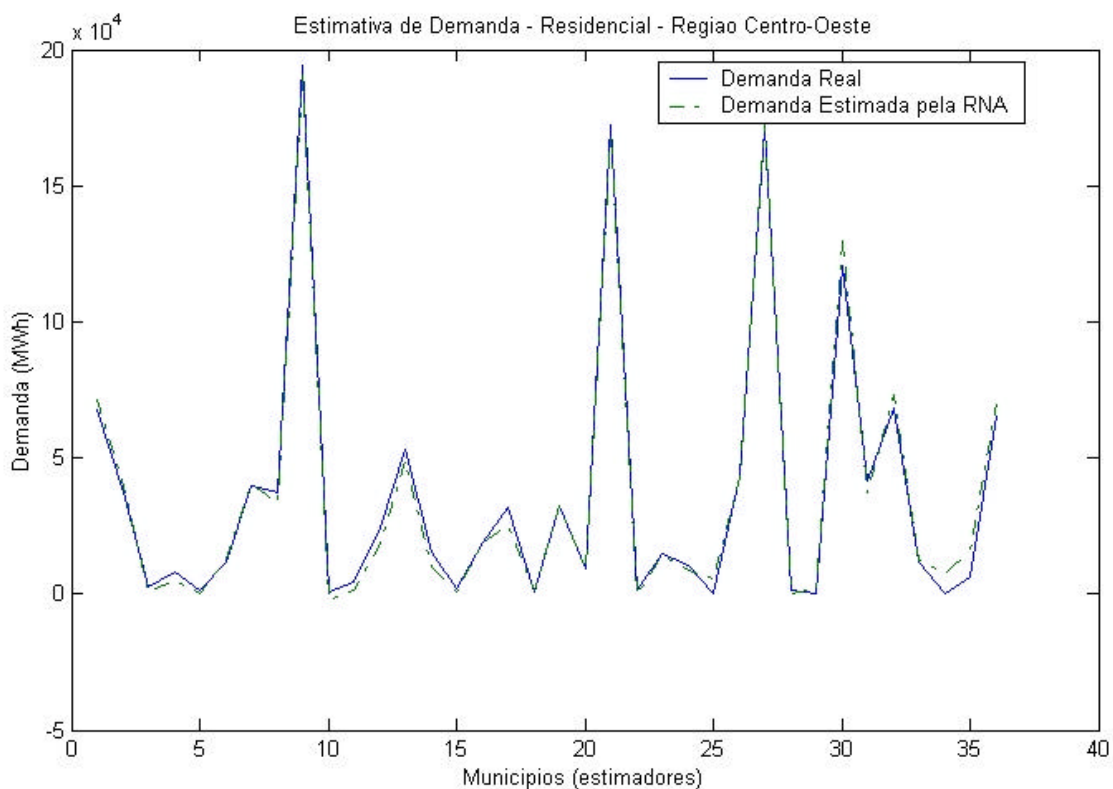


Figura 16 – Estimativa de demanda residencial – Região Centro-Oeste.

Fonte: Elaborado pelo autor.

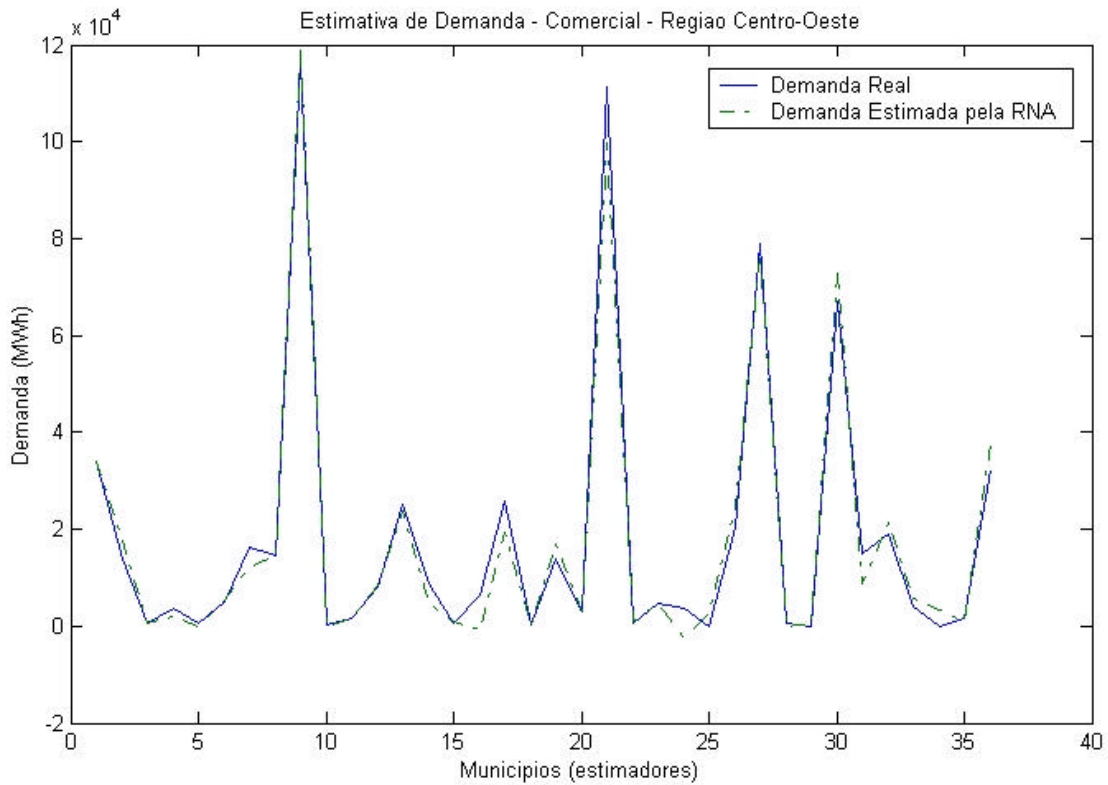


Figura 17 – Estimativa de demanda comercial – Região Centro-Oeste.

Fonte: Elaborado pelo autor.

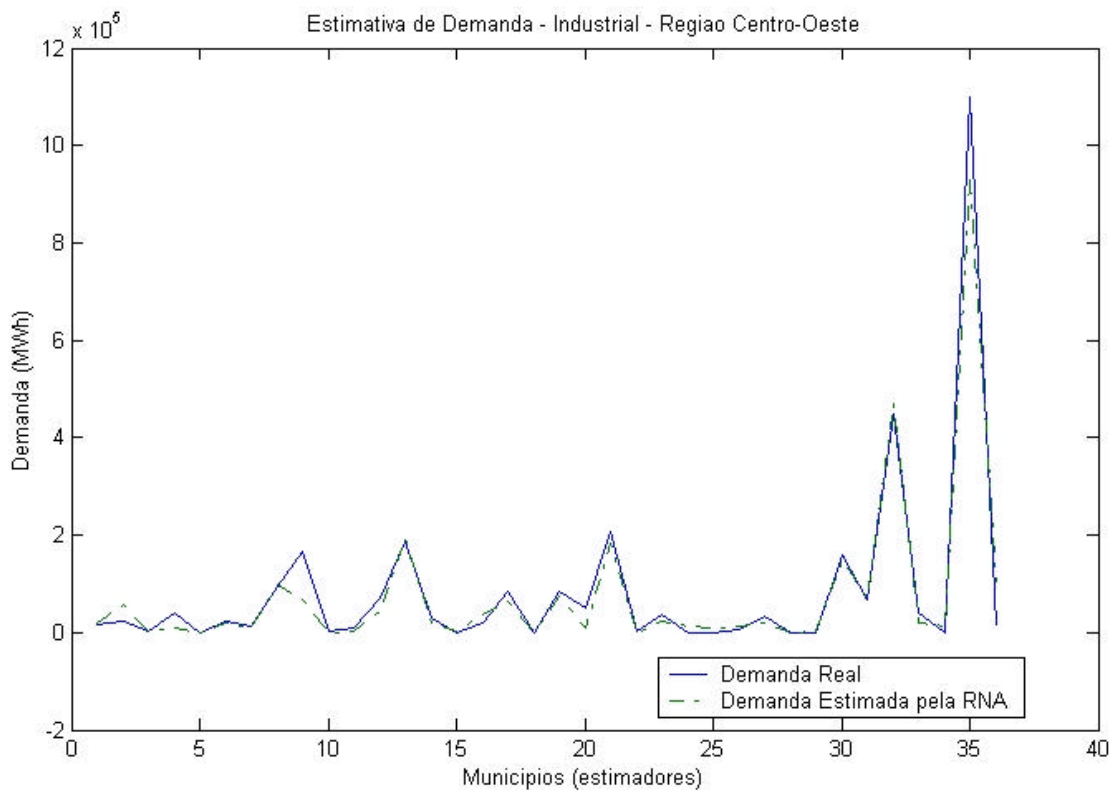


Figura 18 – Estimativa de demanda industrial – Região Centro-Oeste.

Fonte: Elaborado pelo autor.

4.5.2 Região Sul, Litoral e Porto Alegre

Amostra de tamanho $n_2 = 38$, abrangendo os seguintes municípios: Alvorada, Arroio do Sal, Arroio dos Ratos, Bagé, Camaquã, Candiota, Capão do Leão, Cerrito, Cerro Grande do Sul, Charqueadas, Chuí, Chuvisca, Cristal, Dom Feliciano, Dom Pedrito, Dom Pedro de Alcântara, Encruzilhada do Sul, Hulha Negra, Jaguarão, Lavras do Sul, Morrinhos do Sul, Pantano Grande, Pedro Osório, Pelotas, Pinheiro Machado, Porto Alegre, Rio Grande, São Jerônimo, São José do Norte, São Lourenço do Sul, Sentinela do Sul, Santa Vitória do Palmar, Terra de Areia, Torres, Três Cachoeiras, Turucu e Viamão.

Tabela 13 – DPRs para a região Sul, Litoral e Porto Alegre

SETOR	DPR
RESIDENCIAL	6,8850E + 03
COMERCIAL	1,3969E + 04
INDUSTRIAL	5,6712E + 04

Fonte: Elaborado pelo autor.

As Figuras 19, 20 e 21 mostram a boa convergência nos resultados das demandas residencial e comercial. A demanda industrial, representada na Figura 21, não apresentou convergência.

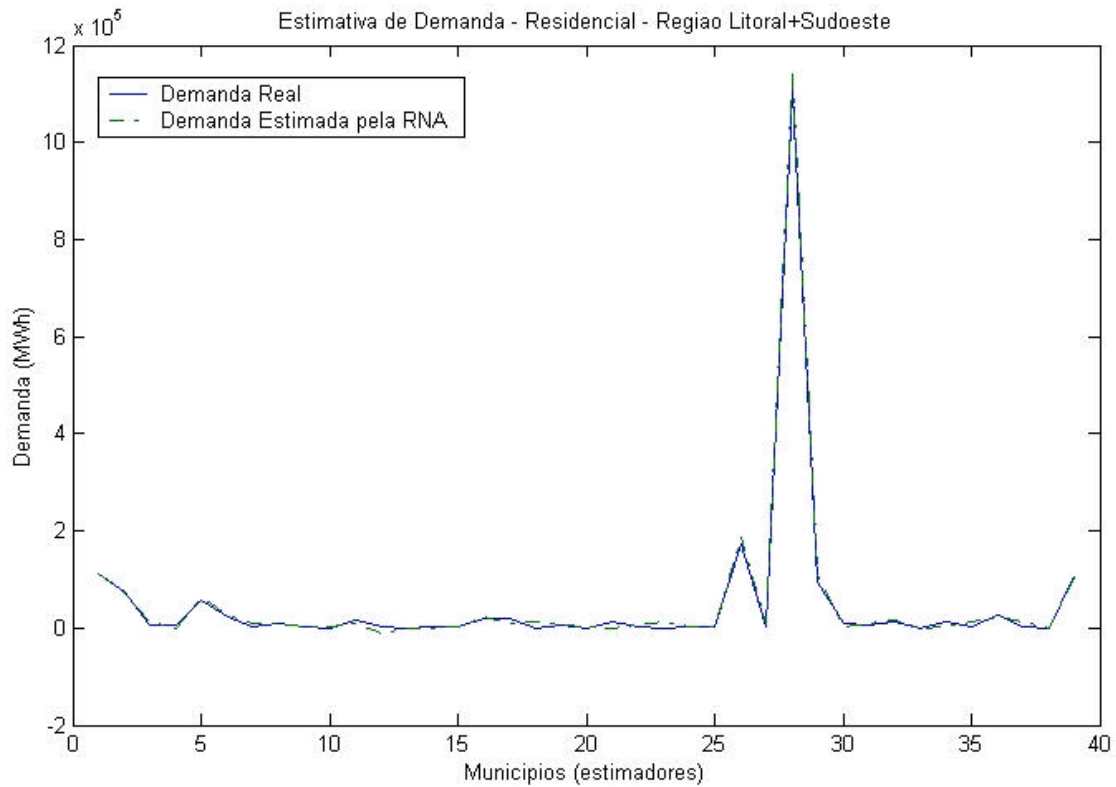


Figura 19 – Estimativa de demanda residencial – Região Litoral e Sudoeste.

Fonte: Elaborado pelo autor.




Figura 20 – Estimativa de demanda comercial – Região Litoral e Sudoeste.

Fonte: Elaborado pelo autor.

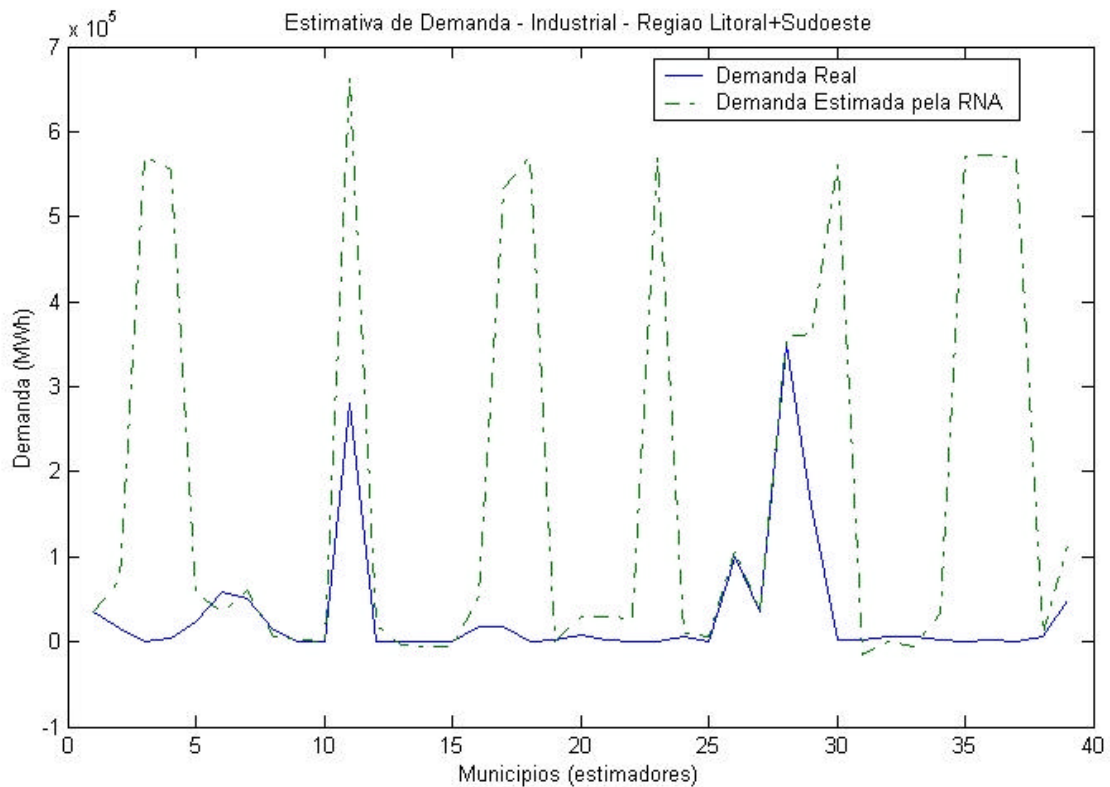


Figura 21 – Estimativa de demanda industrial – Região Litoral e Sudoeste.

Fonte: Elaborado pelo autor.

4.5.3 Região Norte

Amostra de tamanho $n_3 = 52$, com os seguintes municípios: Água Santa, Alpestre, Ametista do Sul, Antônio Prado, Bento Gonçalves, Bom Jesus, Cachoeirinha, Cambará do Sul, Canela, Caseiros, Caxias Do Sul, Coxilha, Cruz Alta, Dezesesseis de Novembro, Esmeralda, Farroupilha, Flores da Cunha, Frederico Westphalen, Gramado, Gravataí, Ibirubá, Ijuí, Ipiranga do Sul, Irai, Jaquirana, Lagoa dos Três Cantos, Lagoa Vermelha, Monte Alegre dos Campos, Monte Belo do Sul, Muitos Capões, Nova Hartz, Nova Pádua, Nova Roma do Sul, Passo Fundo, Pejuçara, Pirapó, Planalto, Quinze de Novembro, Roque Gonzáles, Santo Expedito Do Sul, São Francisco de Paula, São José Dos Ausentes, São Luiz Gonzaga, São Marcos, São Nicolau, Selbach, Tapejara, Tapera, Vacaria, Veranópolis e Vicente Dutra.

Tabela 14 – DPRs para a região Norte

SETOR	DPR
RESIDENCIAL	5,6689E + 03
COMERCIAL	1,8923E + 03
INDUSTRIAL	7,4757E + 03

Fonte: Elaborado pelo autor.

As Figuras 22, 23 e 24 mostram que houve convergência nos três setores focalizados neste estudo.

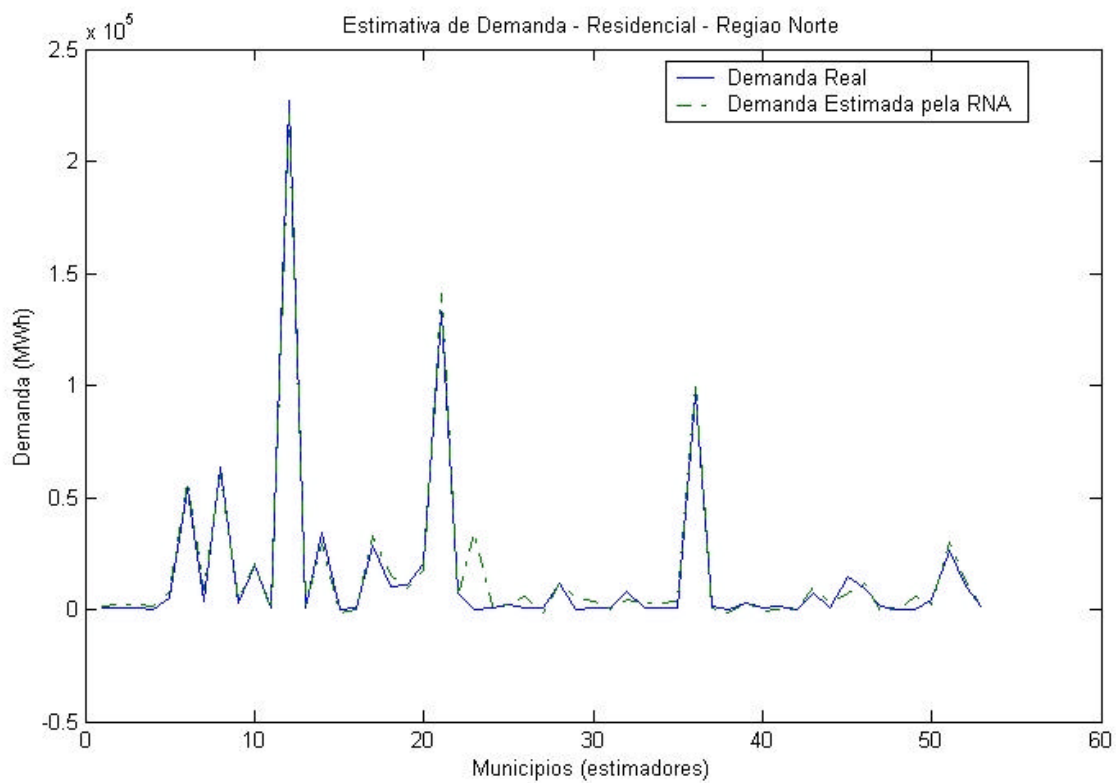


Figura 22 – Estimativa de demanda residencial – Região Norte.

Fonte: Elaborado pelo autor.




Figura 23 – Estimativa de demanda comercial – Região Norte.

Fonte: Elaborado pelo autor.

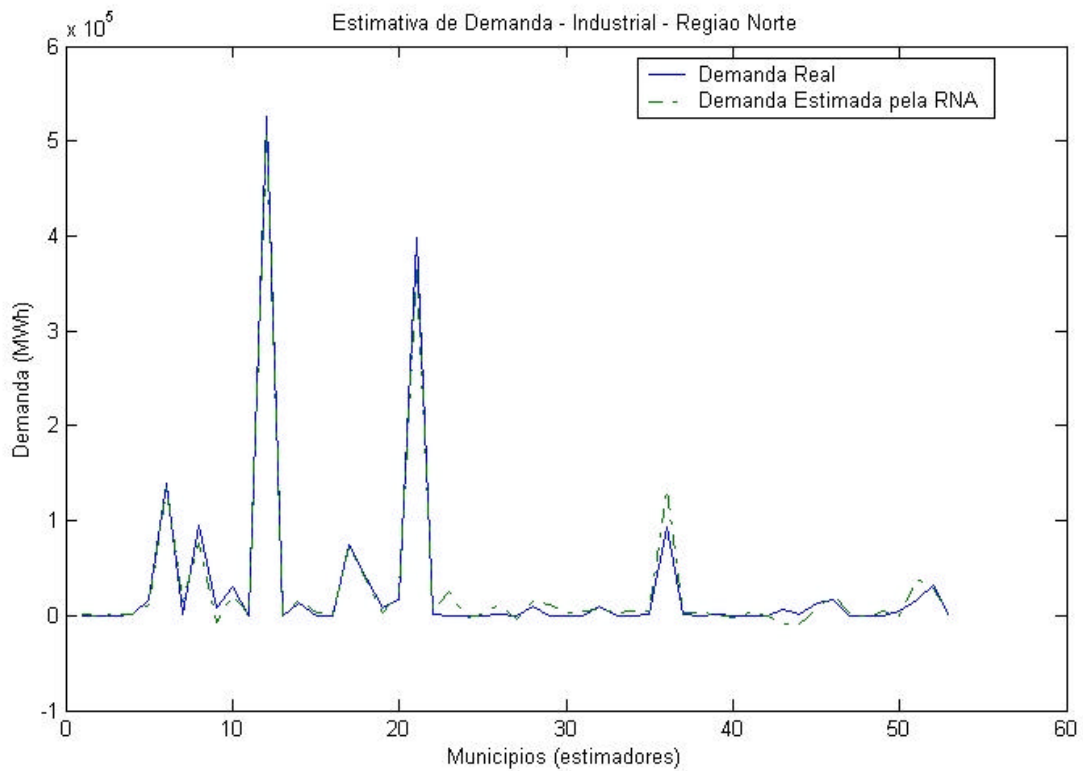


Figura 24 – Estimativa de demanda industrial – Região Norte.

Fonte: Elaborado pelo autor.

4.5.4 Comparação entre a regionalização e o modelo padrão de rede neural

Para proceder a comparação dos modelos regionalizados com o modelo padrão deste estudo, foi calculada a média ponderada dos DPRs de cada região para cada setor de demanda de energia elétrica, do seguinte modo:

$$DPR_{m\u00e9dio} = \frac{\sum_{i=1}^3 n_i \times DPR_i}{\sum_{i=1}^3 n_i} \quad (4.8)$$

onde

n_i é o tamanho da sub-amostra;

DPR_i é o Desvio Padrão Residual da sub-amostra.

$i = 1, 2, 3$

Os resultados estão na Tabela a seguir.

Tabela 15 – Comparação entre o modelo regionalizado e a rede padrão

	Residencial	Comercial	Industrial
$DPR_{m\u00e9dio}$	5,6368E + 03	5,9549E + 03	2,7786E + 04
DPR_{rede}	6,8041E + 03	6,1689E + 03	7,8883E + 04
$\Delta\%$	-17%	-3%	-65%

Fonte: Elaborado pelo autor.

Houve diminuição nos DPRs dos três modelos estudados por ocasião da regionalização, com sensível melhora do modelo para a previsão de energia elétrica no setor industrial.

As Figuras 18, 21 e 24 mostram graficamente os resultados da demanda industrial. Percebe-se que somente nas regiões Sul, Litoral e Porto Alegre houve problema de convergência. Este fato indica que, provavelmente nesta região, existam características – tipo de indústria, por exemplo – que mereçam maior atenção em estudos futuros.

É necessário ressaltar que, apesar dos resultados apresentados na Tabela 15 mostrarem uma diminuição no erro de predição, a arquitetura da rede não sofreu qualquer adaptação ao número de exemplos usados em cada sub-amostra, conforme mencionado na Seção 4.3, a fim de adequar o modelo a cada caso. Um refinamento no modelo está previsto para a continuação deste estudo. Os resultados coletados com esta seção de testes apenas indicam que trabalhar com amostras de menor tamanho, desde que respeitadas as premissas do número de exemplos de treinamento da rede e de sua topologia, tendem a apresentar resultados melhores do que no caso de grandes amostras, abrangendo regiões de diferentes características, que podem levar a rede neural a não captar a correta relação entre a entrada e a saída, com a consequente perda de generalização.

5 CONCLUSÕES E ESTUDOS FUTUROS

Este estudo foi desenvolvido com o propósito de criar um modelo para a previsão de demanda de energia elétrica, que se apresente como uma alternativa aos tradicionalmente usados (Box-Jenkins, por exemplo), trazendo vantagens em termos de versatilidade e maior precisão. A ferramenta computacional utilizada – redes neurais artificiais – é apontada por diversos autores, citados ao longo do trabalho, como de maior eficiência na previsão de demandas. Ao longo deste estudo, a comparação entre os modelos implementados por redes neurais e regressão estatísticas evidenciou que uma das principais vantagens do uso de redes neurais para o modelo preditivo é a capacidade desta de trabalhar com dados que apresentem grande aleatoriedade (ruído), visto que o modelo desenvolvido por meio da técnica estatística de regressão linear multivariada é útil para ajustes de sistemas cujas respostas não contenham uma grande variedade de fatores interferentes (ruídos). Esta limitação reside no fato de a informação contida na matriz de variáveis independentes ser inteiramente incorporada ao modelo de regressão. Desse modo, a informação irrelevante também estará presente no modelo de regressão, reduzindo sua precisão para estabelecer estimativas confiáveis (ARAÚJO et al, 2005). Dentre as vantagens das redes neurais frente aos modelos paramétricos, destacam-se: (a) capacidade de generalização, mesmo com dados incompletos ou imprecisos; e (b) imunidade a ruídos – as redes conseguem separar o ruído da informação relevante (DAHMER, 1998).

Os resultados apresentados mostram que modelos preditivos baseados em redes neurais artificiais são uma alternativa viável aos métodos tradicionais, os ditos modelos paramétricos, que utilizam ferramentas estatísticas na sua determinação. Comparativamente, este estudo mostrou vantagens na utilização das redes neurais sobre os modelos tradicionais. Uma destas vantagens diz respeito à versatilidade da rede neural, visto que, ocorrendo variações no cenário em estudo, é suficiente que a rede seja treinada novamente para realocar seus pesos sinápticos, ao passo que o modelo paramétrico requer uma total reformulação. Segundo o Balanço Energético Nacional (BRASIL. MINISTÉRIO DE MINAS E ENERGIA, 2004), no setor elétrico a previsão de demanda é realizada primordialmente em três horizontes temporais: (a) longo prazo: de 20 a 30 anos; (b) médio prazo: de 10 a 15 anos;

e (c) curto prazo: inferior a 10 anos. Tais previsões são revistas em períodos que variam de um a cinco anos, conforme o tipo de planejamento. Neste pormenor, a revisão no modelo seria muito simplificada com o uso de redes neurais, bastando um novo treinamento da rede para que o modelo se ajuste ao novo cenário.

Seguindo-se recomendações apontadas na literatura como primordiais ao bom desempenho da rede neural, foi dada especial atenção a três aspectos da rede neural:

a) seleção de variáveis adequadas aos setores de demanda estudados;

b) arquitetura da rede neural; e

c) treinamento da rede, através de um algoritmo adequado tanto à minimização do erro de aprendizagem, quanto com relação à garantia de boa generalização (menor erro de predição possível).

Sob estes aspectos, foram obtidos resultados satisfatórios, com a confirmação da importância das quatro variáveis selecionadas para este estudo: temperatura, umidade do ar, PIB e população. Os modelos residencial e comercial apresentaram resultados muito próximos dos reais, com forte vinculação às variáveis climáticas – temperatura e umidade relativa do ar, bem como das variáveis econômicas: PIB e população. Já o modelo industrial mostrou maior sensibilidade apenas à variável PIB, se comparada com as respostas dos outros setores às demais variáveis utilizadas na entrada da rede neural. Conforme Setyawati et al (2003) e Haykin (2001), a quantidade de variáveis selecionadas exerce um papel fundamental no desempenho da rede neural. A dependência do setor industrial apenas à variável PIB demonstra a necessidade do levantamento de outras variáveis, que, juntamente com a variável PIB, forneçam resultados de maior credibilidade à previsão de demanda deste setor.

Outro fator que requer cuidados especiais em sua determinação é a topologia da rede. Neste estudo, a topologia que apresentou resultados mais estáveis possui cinco neurônios na primeira camada oculta, 15 na segunda camada oculta e apenas um na saída da rede. Variações na topologia da rede mostram que esta é bastante sensível no que se refere ao seu número de neurônios, podendo, inclusive, não apresentar convergência em determinados casos.

A regionalização do modelo foi introduzida neste estudo com o propósito de verificar a adequação do modelo à quantidade de exemplos de treinamento. Embora se tenha obtido uma redução no erro de predição, principalmente no setor industrial, a arquitetura da rede foi mantida, o que, segundo a literatura pertinente, não é recomendado, visto que a arquitetura da

rede também pode depender do tamanho da amostra. Os resultados colhidos, neste caso, apenas apontam uma tendência de que o modelo pode apresentar maior precisão quando trabalhar com amostras de menor tamanho.

Em geral, os resultados levantados neste estudo mostram que é válido o uso de redes neurais artificiais como uma alternativa aos modelos paramétricos tradicionais. Entretanto, ainda permanece uma incerteza no uso de tais modelos ditos “modernos”, pois, conforme foi mencionado por Goedel (2003), neste campo de estudos ainda predomina o empirismo, com várias teorias formuladas, mas que ainda não convergiram para um paradigma que permita aos pesquisadores chegarem a conclusões definitivas. Pode-se dizer que o campo de pesquisas encontra-se em aberto, e, a cada dia, novas e importantes descobertas vão sendo feitas. Uma certeza que se tem é a de que existe um grande interesse de gestores e pesquisadores por tais métodos de previsão.

Estão previstos estudos futuros nesta linha de pesquisa, a fim de contemplar os seguintes itens:

- a) seleção de variáveis adequadas à previsão de demanda de energia elétrica dos setores rural e público, bem como a seleção de variáveis adicionais para o melhoramento da predição no setor industrial;
- b) estudo e testes de outras arquiteturas de redes neurais artificiais;
- c) aprimoramento do modelo atual, buscando o aumento da precisão.

Com base em avaliação feita no artigo de Araújo; Becker e Goedel (2005), pela Comissão Avaliadora do VII Brazilian Symposium on Intelligent Automation – II Latin American Robotics Symposium (VII SBAI – II LARS), uma comparação deve ser feita com técnicas mais modernas, como por exemplo, a de lógica difusa, e não com uma simples regressão. A avaliação do artigo destaca que se trata de uma abordagem interessante, principalmente no que diz respeito às variáveis de entrada da RNA (fatores climáticos e econômicos), embora não tenha sido explicitado no artigo o comportamento destas, ou a forma com que estas deveriam ser tratadas ou modeladas para o horizonte de 10 a 20 anos.

Estudos futuros deverão ter, como foco, a utilização de outras técnicas inteligentes no sentido de aprimorar a presente ferramenta de predição de demanda, tornando-a ainda mais robusta, bem como tratar da avaliação de cenários para estimação de longo prazo.

REFERÊNCIAS

- ABRAHAM, A.; NATH, B. A neuro-fuzzy approach for modeling electricity demand in Victoria. Amsterdam, **Applied Soft Computing Journal**, v. 1/2, p. 127-138, 2001.
- ALVES, A. A. F. **Construção de cenários de demanda no setor residencial: uma abordagem baseada em dinâmica de sistemas**. 1997. vx, 121 f.: il. Dissertação (Mestrado) – Universidade Federal de Santa Catarina, Centro Tecnológico. Florianópolis, 1997.
- ARAÚJO, M. A. G.; BECKER, J. L.; GOEDEL, A. **Estimativa de demanda de energia elétrica em setores diversos, usando redes neurais artificiais**. Trabalho aceito em 17 de julho de 2005 pela organização do VII SBAI – Brazilian Symposium on Intelligent Automation – II LARS – IEEE Latin American Robotics Symposium a realizar-se em setembro de 2005 em São Luiz -MA.
- AUDY, J. L. N.; BRODBECK, A. F. **Sistemas de informação: planejamento e alinhamento estratégico nas organizações**. Bookman: Porto Alegre, 2003.
- BEER, S. **Cibernética na administração: visão totalmente original de como organizar e administrar desde uma pequena empresa até um país**. Tradução Jose Reis. São Paulo: IBRASA, 1979. Tradução de: The brain of the firm.
- BERRY, M. J. A.; LINOFF, G. **Data mining techniques: for marketing, sales, and customer support**. New York: J. Wiley, 1997.
- BJORGAN, R., SONG, H., LIU, C. C., DAHLGREN, R.. Pricing flexible electricity contracts. Amsterdam, **IEEE Transactions on Power Systems**, v. 15, n. 2, p. 477-482, May 2000.
- BOLZERN, P.; FRONZA, G. **Role of weather inputs in short-term forecasting of electric load**. Dipartimento di Elettronica, Centro Teoria dei Sistemi. CNR, Politecnico di Milano, Piazza, Milan, Italy, 1986.
- BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000.
- BRANCO, T. M. M. **Planejamento econômico de sistemas de energia elétrica: uma abordagem multiobjetiva linearizada para solução**. 1986. [107] p. Tese (Doutorado) – Universidade Federal do Pará. Centro Tecnológico. Departamento de Eletricidade. Belém, 1986.
- BRASIL. Medida provisória n. 144, de 11 de dezembro de 2003. Diário Oficial [da] República Federativa do Brasil, Poder Executivo, Brasília, DF, 11 dez 2003, Seção Extra, p. 2. Disponível em: <http://www6.senado.gov.br/sicon/ExecutaPesquisaLegislacao.action>. Acesso em: 23 jan 2004.
- BRASIL. MINISTÉRIO DE MINAS E ENERGIA ELETROBRAS. **Plano Nacional de Energia Elétrica 1993/2015 = Plano 2015**. 1994. 5 v. Disponível em: http://www.eletrobras.gov.br/EM_Biblioteca/publicacoes.asp. Acesso em: 06 fev 2004.

BRASIL. MINISTÉRIO DE MINAS E ENERGIA. **Balanco Energético Nacional**. 2004. Disponível em: http://www.mme.gov.br/site/menu/select_main_menu_item.do?channelId=1432&pageId=1587. Acesso em: 06 fev 2004.

BRASIL. MINISTÉRIO DE MINAS E ENERGIA. ELETROBRAS. **Plano decenal de expansão 1999/2008 = Plano 2010**. 1999. Disponível em: http://www.eletrobras.com.br/EM_Biblioteca/publicacoes.asp. Acesso em: 06 fev 2004.

CAETANO, M. M. **Histórico e Perspectivas Futuras da Oferta e do Consumo de Eletricidade no Estado do Rio de Janeiro-1980/2004**: padrões de suprimento energético e de desenvolvimento estadual. vi, 156 p.: il. Dissertação (Mestrado) – Universidade Federal do Rio de Janeiro. Instituto de Pós-Graduação e Pesquisa em Engenharia. Programa de Planejamento Energético. Rio de Janeiro, 1997.

CAIO, L. S. **Análise das metodologias de previsão de mercado de energia elétrica**: relações macroeconômicas e o novo perfil no ambiente pós-privatização. 1998. 227 p. Dissertação (Mestrado) – Universidade de São Paulo. Energia. Programa Interunidades de Pós-Graduação em Energia. São Paulo, 1998.

CARBONELL, J. G. Paradigms for machine learning. **Artificial intelligence** (special issue on machine learning), vol. 40, 1989 *apud* GOEDEL, A. **Estimativa de conjugado de carga aplicado em eixos de motores de indução trifásicos através de redes neurais artificiais**. 2003. 122 f. Dissertação (Mestrado) – Universidade Estadual Paulista. Faculdade de Engenharia de Bauru. Bauru, 2003.

CARLSSON C.; TURBAN, E. DSS: directions for the next decade. Amsterdam, **Decision Support Systems**, v. 33, n. 2, p. 105-110, June 2002.

CARPINTEIRO, O. A. S.; REIS, A. J. R. A hierarchical self-organizing map model in short term load forecasting. *In*: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 15. Gramado, 2004. **Anais...** Gramado: UFRGS, 2004. 1 CD-ROM, *paper n.* 548.

COURTNEY, J. F. Decision making and knowledge management in inquiring organizations: toward a new decision-making paradigm for DSS. Amsterdam, **Decision Support Systems**, v. 31, n. 1, p. 17-38, May 2001.

CRAINER, S. **Grandes pensadores da administração**: as idéias que revolucionaram o mundo dos negócios. São Paulo: Futura, 2000.

CRATOCHVIL, A. **Data mining techniques in supporting decision making**. 1999. 57 f. Master thesis – Universiteit Leiden. Disponível em: <http://www.cs.unimaas.nl/~kuyper/publications/papers/scripties/andac/andac.html>. Acesso em: 11 set 2003.

DAHMER, A. **Segmentação de imagens ecocardiográficas utilizando redes neurais e medidas de textura**. 1998. 100 f: il. Dissertação (Mestrado) – Universidade Federal do Rio Grande do Sul. Instituto de Informática. Curso de Pós-Graduação em Ciência da Computação, Porto Alegre, 1998.

FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From data mining to knowledge discovery: an overview. *In*: FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. (Editors) **Advances in knowledge discovery and data mining**. Cambridge: AAAI/MIT, 1996. p. 1-36.

FISH, K. E; BLODGETT, J. G. A visual method for determining variable importance in an artificial neural net. London, **Journal of Targeting, Measurement and Analysis for Marketing**, v. 11, n. 3; p. 244-254, March 2003.

- FLORES, E. D. **Previsão de uma série temporal da área de energia elétrica usando um modelo de rede neural difusa com retropropagação**. Relatório PIC. 28 p. Santa Maria: UFMS, 2000.
- FORESEE, F. D.; HAGAN, M. T. Gauss-Newton approximation to bayesian learning. *In: INTERNATIONAL CONFERENCE OF NEURAL NETWORKS, 1997. Proceedings...* v. 3, p. 1930-1935.
- FREITAS, A. A. **Understanding the crucial differences between classification and discovery of association rules – a position paper**. 2000. Disponível em: <http://www.peakstrategy.net/NEWS/AssociationRules.pdf>. Acesso em: 12 set 2003.
- GOEBEL, M.; GRUENWALD, L. **A survey of data mining and knowledge discovery software tools**. 1999. Disponível em: http://planimeter.hu/download/pdf_44.pdf. Acesso em: 03 set 2003.
- GOEDEL, A. **Estimativa de conjugado de carga aplicado em eixos de motores de indução trifásicos através de redes neurais artificiais**. 2003. 122 f. Dissertação (Mestrado) – Universidade Estadual Paulista. Faculdade de Engenharia de Bauru. Bauru, 2003.
- GONZALEZ, J. A. **Modelo estocástico de produção de energia usando o método dos cumulantes considerando unidades com limitação de energia**. 1991. 166 p. Dissertação (Mestrado) – Universidade Federal de Santa Catarina. Centro Tecnológico. Florianópolis, 1991.
- GROTH, R. **Data mining: a hands-on approach for business professionals**. Upper Saddle River: Prentice Hall PTR, c1998.
- HAGAN, M. T.; MENHAJ, M. B. Training feed forward networks with the Marquardt algorithm. New York, **IEEE Transactions on Neural Networks**, v. 5, n. 6, p. 989-992, November 1994.
- HAYKIN, S. **Redes neurais: princípios e prática**. Tradução Paulo Martins Engel. 2. ed. Porto Alegre: Bookman, 2001. Tradução de Neural networks: a comprehensive foundation.
- HEBB, D. O. **The organization of behavior: a neuropsychological theory**. New York: Wiley, 1949 *apud* HAYKIN, S. **Redes neurais: princípios e prática**. Tradução Paulo Martins Engel. 2. ed. Porto Alegre: Bookman, 2001. Tradução de Neural networks: a comprehensive foundation.
- HOBBS, B. F.; HELMAN, U., JITPRAPAIKULSARN, S., SREENIVAS, K., MARATUKULAN, D. Artificial neural networks for short-term energy forecasting: accuracy and economic value. Amsterdam, **Neurocomputing**, v. 23, n. 1/3, p. 71–84, December 1998.
- KERMANSHAHI, B. Recurrent neural network for forecasting next 10 years loads of nine Japanese utilities. Amsterdam, **Neurocomputing**, v. 23, n. 1/3, p. 125–133, December 1998.
- LAW, A. M.; KELTON, W. D. **Simulation modeling and analysis**. 3rd ed. New York: McGraw-Hill, 2000.
- LEVENBERG, K.; MARQUARDT, D. An algorithm for least squares estimation of non-linear parameters. Philadelphia, **Journal of the Society for Industrial and Applied Mathematics**, v. 11, p. 431-441, 1963.
- LORENTZ, E. G. **Aplicação de redes neurais na previsão de demanda de energia elétrica: um estudo comparativo entre modelos**. 1995. 131 f.: il. Dissertação (Mestrado) – Universidade Federal de Minas Gerais. Escola de Engenharia. Belo Horizonte, 1995.

- MAÇADA; A. C. G. **Impacto dos investimentos em tecnologia da informação nas variáveis estratégicas e na eficiência dos bancos brasileiros**. 2001. [211] p. Tese (Doutorado) – Universidade Federal do Rio Grande do Sul. Departamento de Administração de Empresas. Porto Alegre, 2001.
- MCCULLOCH, W.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. Michigan, **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943.
- REFENES, A-P. **Neural networks in the capital markets**. New York: J. Wiley, 1995.
- RIBEIRO, R. A.; RODRIGUES, A. J.; ZARATÉ, P. Decision support systems: current research. Amsterdam, **European Journal of Operational Research**, n. 145, p. 231, 2003.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, v. 65, p. 386-408, 1958 *apud* HAYKIN, S. **Redes neurais: princípios e prática**. Tradução Paulo Martins Engel. 2. ed. Porto Alegre: Bookman, 2001. Tradução de Neural networks: a comprehensive foundation.
- SANDAK, J.; TANAKA, C. Online adaptive control of band saw feed speed using a fuzzy-neural system. Madison, **Forest Products Journal**, v. 53, n. 6; p. 36, June 2003.
- SANTOS, M. P. **Previsão semanal da carga própria de energia e demanda das concessionárias do sistema interligado Sul/Sudeste**. 1996. v, 111 f.: il. Dissertação (Mestrado) – Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Industrial. Rio de Janeiro, 1996.
- SCHUCH, G. B. **Previsão de demanda de energia elétrica usando a metodologia de Box-Jenkins**. 1988. 154 p. Dissertação (Mestrado) – Universidade Federal de Santa Maria. Santa Maria, 1988.
- SETYAWATI, B. R.; CREESE, R. C.; SAHIRMAN, S. Neural network for cost estimation (part 2). Morgantown, **AACE International Transactions**, v. 14, p. 1-10, 2003.
- SHARMA, J.; KAMATH, R.; TULUCA, S. Determinants of corporate borrowing: an application of a neural network approach. West Haven, **American Business Review**, v. 21, n. 2; p. 63, June 2003
- SHIM, J. P., WANKENTIN, M., COURTNEY, J. F., POWER, D. J., SHARDA, R., CARLSSON, C. Past, present and future of decision support technology. Amsterdam, **Decision Support System**, v. 33, n. 2, p. 111-126, June 2002.
- SOTO, C. P. **Redes neurais temporais para o tratamento de sistemas variantes no tempo**. 1999. ix, 101 f.: il. Dissertação (Mestrado) – Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. Rio de Janeiro, 1999.
- SPOSITO, E. S. **Planejamento da demanda por energia elétrica: necessidades e possibilidades de execução**. 1991. 174 p. Dissertação (Mestrado) – Universidade Federal do Rio de Janeiro. Instituto de Pós-Graduação e Pesquisa em Engenharia. Programa de Planejamento Energético. Rio de Janeiro, 1991.
- TERRAGAUCHA. **Aspectos econômicos do Estado e dos Municípios do RS**. 2003. Disponível em: <http://www.terraGaucha.com.br/economia.htm>. Acesso em; dia mês ano.
- WAGNER, H. M. **Pesquisa Operacional**. Prentice-Hall, Rio de Janeiro, 1986.
- WHEELWRIGHT, S. C.; MAKRIDAKIS, S. **Forecasting methods for management**. 4a. ed. New York: John Wiley & Sons, 1985.

WINSTON, L. W. **Operations Research Applications and Algorithms**. California-Belmont:Duxbury Press, 1994.

ZANDONADE, E. **Aplicação da metodologia de redes neurais em previsão de series temporais**. 1993. vi, 139 f.: il. Dissertação (Mestrado) – Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro, 1993.

ANEXO I – METODOLOGIA

ANEXO II – MAPA CLIMATOLÓGICO

ANEXO III – BASE DE DADOS

ANO: 1999

							PÚBL	RESID.	COML
Município	TM	DPT	URAM	DPU	PIB	POP	(Mwh)	(Mwh)	(Mwh)
BAGÉ	17,475	4,535	65,333	7,901	304637035	117958	14228	58823	20919
Dom Pedrito	17,475	4,535	65,333	7,901	209758744	40005	4388	19119	5049
Lavras do Sul	17,475	4,535	65,333	7,901	23343270	7870	1311	2891	670
Hulha Negra	17,475	4,535	65,333	7,901	24136163	5261	42	146	28
Pinheiro Machado	17,475	4,535	65,333	7,901	84817130	14170	1783	4339	944
Candiota	17,475	4,535	65,333	7,901	190939553	7821	1514	3592	1081
BENTO GONÇALVES	16,992	3,795	75,167	5,557	973978018	89386	21920	55406	28535
Nova Roma do Sul	16,992	3,795	75,167	5,557	20918402	3075	220	772	360
Monte Belo do Sul	16,992	3,795	75,167	5,557	15055544	2863	457	381	161
Nova Pádua	16,992	3,795	75,167	5,557	25075926	2385	152	482	317
Veranópolis	16,992	3,795	75,167	5,557	174766576	19079	4750	9616	5681
Antônio Prado	16,992	3,795	75,167	5,557	75972335	12620	1561	5112	2700
BOM JESUS	14,233	3,682	79,750	4,434	38701491	12104	1249	3819	1885
Jaquirana	14,233	3,682	79,750	4,434	8563571	4690	345	1101	193
Monte Alegre dos Campos	14,233	3,682	79,750	4,434	6884321	2985	390	176	57
Vacaria	14,233	3,682	79,750	4,434	236886673	56338	8785	25963	26501
CAMAQUÃ	17,975	3,918	86,667	3,257	287432751	59639	6833	24961	9593
Cristal	17,975	3,918	86,667	3,257	16865857	6609	961	1618	817
Chuívisca	17,975	3,918	86,667	3,257	11894079	4510	64	173	87
Dom Feliciano	17,975	3,918	86,667	3,257	25631855	13268	679	1114	539
Cerro Grande do Sul	17,975	3,918	86,667	3,257	22250620	8111	288	815	455
Sentinela do Sul	17,975	3,918	86,667	3,257	25501860	4715	272	890	210
CAMBARÁ DO SUL	14,225	3,502	81,167	4,726	43410367	6867	895	2801	576
São José dos Ausentes	14,225	3,502	81,167	4,726	11782251	3095	369	594	87
São Francisco de Paula	14,225	3,502	81,167	4,726	53699583	19552	3167	7549	3030
CAMPO BOM	19,092	4,412	79,500	4,622	586984168	53209	15168	33765	11174
Novo Hamburgo	19,092	4,412	79,500	4,622	1361352545	233475	40571	162995	89264
Nova Hartz	19,092	4,412	79,500	4,622	113795855	14427	1118	7319	1475
Sapiranga	19,092	4,412	79,500	4,622	363425375	67527	6723	36472	12199
Araricá	19,092	4,412	79,500	4,622	11738122	3844	416	2143	584
Estância Velha	19,092	4,412	79,500	4,622	212959525	34143	3288	22061	6886
São Leopoldo	19,092	4,412	79,500	4,622	879181647	190098	31593	125983	61717
Sapucaia do Sul	19,092	4,412	79,500	4,622	763222562	120457	12421	64130	17544
Portão	19,092	4,412	79,500	4,622	189232215	24060	3601	13529	3791
CAXIAS DO SUL	16,183	3,582	79,167	5,374	3230845017	351405	57326	227749	121957
São Marcos	16,183	3,582	79,167	5,374	105292553	18547	3078	9258	3618

ANO: 1999

							PÚBL	RESID.	COML
Município	TM	DPT	URAM	DPU	PIB	POP	(Mwh)	(Mwh)	(Mwh)
Nova Pádua	16,183	3,582	79,167	5,374	25075926	2385	152	482	317
Farroupilha	16,183	3,582	79,167	5,374	495453710	54583	9630	28234	15523
Flores da Cunha	16,183	3,582	79,167	5,374	222922897	22854	3117	9904	4250
Gramado	16,183	3,582	79,167	5,374	122903290	27672	3758	19394	16844
Canela	16,183	3,582	79,167	5,374	95240685	32883	10861	18325	9754
CRUZ ALTA	18,242	4,351	73,417	7,077	247885367	71209	13139	37764	16127
Pejuçara	18,242	4,351	73,417	7,077	33253323	4192	1019	1497	507
Ijuí	18,242	4,351	73,417	7,077	333031605	77726	1	11	1
ENCRUZILHADA DO SUL	17,058	4,322	76,417	5,775	29145058	23621	2247	6030	1941
Santana da Boa Vista	17,058	4,322	76,417	5,775	9068324	8599	830	1362	453
Caçapava do Sul	17,058	4,322	76,417	5,775	103776411	34318	4766	12254	4456
Pantano Grande	17,058	4,322	76,417	5,775	46673463	10830	1023	3841	1950
Cachoeira do Sul	17,058	4,322	76,417	5,775	258150856	87462	10702	40790	15064
IBIRUBÁ	18,100	4,146	79,583	6,259	85238645	18593	2200	7634	3324
Selbach	18,100	4,146	79,583	6,259	31862173	4793	77	168	43
Quinze de Novembro	18,100	4,146	79,583	6,259	21955598	3569	513	789	282
Tapera	18,100	4,146	79,583	6,259	43315098	10590	1599	4931	1762
Lagoa dos Três Cantos	18,100	4,146	79,583	6,259	13191421	1616	244	353	149
IRAÍ	19,867	4,461	73,833	7,814	21663843	7193	1138	2353	1109
Alpestre	19,867	4,461	73,833	7,814	9827069	10462	363	840	384
Planalto	19,867	4,461	73,833	7,814	16930146	11461	2126	2439	1070
Frederico Westphalen	19,867	4,461	73,833	7,814	69032093	26860	2696	11170	6084
Vicente Dutra	19,867	4,461	73,833	7,814	6199307	6175	613	816	603
Ametista do Sul	19,867	4,461	73,833	7,814	20230106	7279	378	20	27
LAGOA VERMELHA	16,233	3,956	76,167	5,670	77606203	29613	4225	11865	5016
Santo Expedito do Sul	16,233	3,956	76,167	5,670	5353200	2702	55	4	51
Esmeralda	16,233	3,956	76,167	5,670	11474330	5522	599	1158	251
Muitos Capões	16,233	3,956	76,167	5,670	22190218	2817	196	341	42
Caseiros	16,233	3,956	76,167	5,670	8820712	2918	296	496	266
PASSO FUNDO	17,208	4,012	72,167	6,206	891597094	165350	27296	98151	58098
Coxilha	17,208	4,012	72,167	6,206	47910547	2985	495	618	331
Tapejara	17,208	4,012	72,167	6,206	53098017	14747	0	0	0
Água Santa	17,208	4,012	72,167	6,206	25508145	4145	307	474	189
Ipiranga do Sul	17,208	4,012	72,167	6,206	13553039	2115	504	358	84
PELOTAS	17,450	4,044	81,500	4,400	977342347	318247	33031	181537	75560
São Lourenço do Sul	17,450	4,044	81,500	4,400	99077170	43356	3485	12272	5240
Turuçu	17,450	4,044	81,500	4,400	21683927	3667	84	595	153
Capão do Leão	17,450	4,044	81,500	4,400	77579722	22997	4001	7826	960
Pedro Osório	17,450	4,044	81,500	4,400	16108029	8038	1202	3197	674
Cerrito	17,450	4,044	81,500	4,400	8117084	6901	513	1365	245

ANO: 1999

							PÚBL	RESID.	COML
Município	TM	DPT	URAM	DPU	PIB	POP	(Mwh)	(Mwh)	(Mwh)
PORTO ALEGRE	19,158	4,154	76,167	4,448	8353777104	1341875	323778	1147876	948750
Canoas	19,158	4,154	76,167	4,448	3485735724	300117	78224	183775	100491
Cachoeirinha	19,158	4,154	76,167	4,448	702476509	104887	19010	64500	29805
Gravataí	19,158	4,154	76,167	4,448	979427195	225520	23311	135201	35402
Alvorada	19,158	4,154	76,167	4,448	131246662	177802	26325	79014	13159
Viamão	19,158	4,154	76,167	4,448	277076125	218764	9502	113340	21346
Esteio	19,158	4,154	76,167	4,448	766157670	78810	24195	51119	16680
RIO GRANDE	17,450	3,926	81,000	8,581	1094214268	184388	35720	99786	43784
São José do Norte	17,450	3,926	81,000	8,581	23159337	23534	1660	5879	1122
S. DO LIVRAMENTO	17,092	4,522	73,833	9,034	232022849	89422	16907	42030	17848
Dom Pedrito	17,092	4,522	73,833	9,034	209758744	40005	4388	19119	5049
SANTA MARIA	18,875	4,571	76,417	6,842	681561619	238970	46607	166148	69514
Restinga Seca	18,875	4,571	76,417	6,842	85436699	16186	4	18	3
Formigueiro	18,875	4,571	76,417	6,842	27407070	7610	570	1679	501
SÃO L. GONZAGA	20,558	4,702	68,000	7,977	100000400	238970	5961	16149	5936
Santo Ant. das Missões	20,558	4,702	68,000	7,977	30416011	12817	104	86	26
Dezesseis de Novembro	20,558	4,702	68,000	7,977	2570048	3471	330	301	124
Roque Gonzales	20,558	4,702	68,000	7,977	14503255	7891	890	1365	540
São Nicolau	20,558	4,702	68,000	7,977	7788132	6439	1051	1378	376
Pirapó	20,558	4,702	68,000	7,977	4098505	3409	170	271	111
STA. VIT. DO PALMAR	16,558	4,098	80,167	4,529	173896576	32677	3231	13422	3225
Chuí	16,558	4,098	80,167	4,529	25982403	4595	467	2712	3587
Jaguarão	16,558	4,098	80,167	4,529	76609301	30026	3433	13902	4661
TEUTÔNIA	18,833	4,380	79,583	5,791	244522168	22150	10	34	43
Colinas	18,833	4,380	79,583	5,791	10350688	2461	323	569	291
Paverama	18,833	4,380	79,583	5,791	18552313	7703	398	912	386
Arroio do Meio	18,833	4,380	79,583	5,791	163569921	16625	1891	7144	3018
Lajeado	18,833	4,380	79,583	5,791	402068730	62662	9407	31201	23413
Estrela	18,833	4,380	79,583	5,791	195745443	27153	5203	15066	7774
Cruzeiro do Sul	18,833	4,380	79,583	5,791	47383932	11617	890	4093	1278
TORRES	19,158	3,701	83,583	1,881	71477904	29577	6763	25170	12417
Morinhos do Sul	19,158	3,701	83,583	1,881	5981533	3549	363	504	278
Arroio do Sal	19,158	3,701	83,583	1,881	7511830	4957	2805	6407	2983
Dom Pedro de Alcântara	19,158	3,701	83,583	1,881	3731159	2542	257	535	340
Três Cachoeiras	19,158	3,701	83,583	1,881	14889907	9440	779	3593	1590
Terra de Areia	19,158	3,701	83,583	1,881	15375676	11269	1588	4031	1492
TRIUNFO	19,300	4,139	88,083	3,288	1752516375	6533	8583	6418	1930
Nova Santa Rita	19,300	4,139	88,083	3,288	127346558	14836	2524	8379	1926
Charqueadas	19,300	4,139	88,083	3,288	215465929	29247	9596	14781	4263
São Jerônimo	19,300	4,139	88,083	3,288	43719960	20135	1544	9308	3569

ANO: 1999

Município	TM	DPT	URAM	DPU	PIB	POP	PÚBL	RESID.	COML
							(Mwh)	(Mwh)	(Mwh)
Taquari	19,300	4,139	88,083	3,288	168432133	25817	2831	11456	3723
Montenegro	19,300	4,139	88,083	3,288	318386161	53232	8262	30963	12257
Arroio dos Ratos	19,300	4,139	88,083	3,288	23401308	13143	1695	6210	1316
URUGUAIANA	19,292	5,106	68,833	8,611	452544166	125312	16176	67919	30812
Itaqui	19,292	5,106	68,833	8,611	329917680	39374	7192	19290	6494
Barra do Quaraí	19,292	5,106	68,833	8,611	42668360	3766	353	1156	653
Quaraí	19,292	5,106	68,833	8,611	68474088	23813	3687	10497	3423
Maçambará	19,292	5,106	68,833	8,611	45161320	4952	435	872	225
Alegrete	19,292	5,106	68,833	8,611	306823130	83871	12474	39164	13025

ANO: 2000

Município	TM	DPT	URAM	DPU	PIB	POP	PÚBL	RESID.	COML
							(Mwh)	(Mwh)	(Mwh)
BAGÉ	17,32	4,50	65,25	8,47	271588199	118747	15262	60198	22318
Dom Pedrito	17,32	4,50	65,25	8,47	164359014	40273	4860	19607	5186
Lavras do Sul	17,32	4,50	65,25	8,47	24203342	7923	1310	2923	688
Hulha Negra	17,32	4,50	65,25	8,47	26134036	5296	94	130	43
Pinheiro Machado	17,32	4,50	65,25	8,47	83735212	14265	1697	4456	1047
Candiota	17,32	4,50	65,25	8,47	162814756	7873	1891	3589	1319
BENTO GONÇALVES	17,04	3,69	75,75	4,20	945274639	91505	21485	56797	31845
Nova Roma do Sul	17,04	3,69	75,75	4,20	24557521	3148	254	818	420
Monte Belo do Sul	17,04	3,69	75,75	4,20	19432693	2931	523	406	179
Nova Pádua	17,04	3,69	75,75	4,20	25860356	2442	156	490	366
Veranópolis	17,04	3,69	75,75	4,20	181811812	19531	5185	10444	6516
Antônio Prado	17,04	3,69	75,75	4,20	81718787	12919	1574	5383	3007
BOM JESUS	14,53	3,71	80,08	3,40	35623060	12031	1294	3928	2682
Jaquirana	14,53	3,71	80,08	3,40	7919592	4662	418	1205	222
Monte Alegre dos Campos	14,53	3,71	80,08	3,40	9022784	2967	417	195	54
Vacaria	14,53	3,71	80,08	3,40	237985140	55998	9232	26623	29458
CAMAQUÃ	17,91	4,34	83,08	3,78	287924495	60368	6793	25793	10428
Cristal	17,91	4,34	83,08	3,78	19287539	6690	977	1636	809
Chuívisca	17,91	4,34	83,08	3,78	12532008	4565	79	194	99
Dom Feliciano	17,91	4,34	83,08	3,78	26436635	13430	703	1143	592
Cerro Grande do Sul	17,91	4,34	83,08	3,78	21788489	8210	307	868	460
Sentinela do Sul	17,91	4,34	83,08	3,78	23460166	4773	301	951	253
CAMBARÁ DO SUL	14,51	3,44	81,42	4,64	41822838	6843	901	2805	628
São José dos Ausentes	14,51	3,44	81,42	4,64	11649577	3084	377	677	106
São Francisco de Paula	14,51	3,44	81,42	4,64	48376293	19484	3557	7770	3042
CAMPO BOM	24,23	19,33	79,00	2,95	596746430	54019	15176	35705	12588
Novo Hamburgo	24,23	19,33	79,00	2,95	1533103447	237029	41751	173207	95291

ANO: 2000

Município	TM	DPT	URAM	DPU	PIB	POP	PÚBL	RESID.	COML
							(Mwh)	(Mwh)	(Mwh)
Nova Hartz	24,23	19,33	79,00	2,95	125037137	14647	1226	8005	1671
Sapiranga	24,23	19,33	79,00	2,95	360074461	68555	6946	39090	13468
Araricá	24,23	19,33	79,00	2,95	11692404	3903	424	2182	531
Estância Velha	24,23	19,33	79,00	2,95	201913094	34663	3511	23371	7057
São Leopoldo	24,23	19,33	79,00	2,95	925136650	192992	32272	132180	67806
Sapucaia do Sul	24,23	19,33	79,00	2,95	787032847	122291	12869	66723	19620
Portão	24,23	19,33	79,00	2,95	209221328	24426	3704	14201	4099
CAXIAS DO SUL	16,44	3,47	78,50	3,15	3346268970	360223	60539	237570	137892
São Marcos	16,44	3,47	78,50	3,15	115449348	19012	3393	9866	4075
Nova Pádua	16,44	3,47	78,50	3,15	25860356	2445	156	490	366
Farroupilha	16,44	3,47	78,50	3,15	504393198	55953	10437	29509	17392
Flores da Cunha	16,44	3,47	78,50	3,15	230394477	23427	3371	10797	5144
Gramado	16,44	3,47	78,50	3,15	132332066	28366	3474	20439	18128
Canela	16,44	3,47	78,50	3,15	103604191	33708	10507	19451	10553
CRUZ ALTA	18,29	4,22	74,00	3,16	205264650	71236	13917	37978	16801
Pejuçara	18,29	4,22	74,00	3,16	33215362	4194	1116	1514	546
Ijuí	18,29	4,22	74,00	3,16	277656644	77755	1	9	13
ENCRUZILHADA DO SUL	17,05	4,24	76,42	4,48	34147685	23897	2498	6681	2196
Santana da Boa Vista	17,05	4,24	76,42	4,48	9059403	8699	675	1460	523
Caçapava do Sul	17,05	4,24	76,42	4,48	106894111	34719	4600	12637	4824
Pantano Grande	17,05	4,24	76,42	4,48	45655119	10957	1210	3983	2233
Cachoeira do Sul	17,05	4,24	76,42	4,48	241809074	88484	10416	41332	15780
IBIRUBÁ	17,98	4,28	79,17	3,88	98736360	18633	2455	7647	3354
Selbach	17,98	4,28	79,17	3,88	27631862	4803	109	174	55
Quinze de Novembro	17,98	4,28	79,17	3,88	22760668	3577	545	838	302
Tapera	17,98	4,28	79,17	3,88	36351509	10613	1803	4745	1849
Lagoa dos Três Cantos	17,98	4,28	79,17	3,88	10422902	1619	288	356	138
IRAÍ	20,03	4,52	75,33	5,00	17073421	7162	1139	2396	1224
Alpestre	20,03	4,52	75,33	5,00	9093100	10417	374	948	435
Planalto	20,03	4,52	75,33	5,00	18417125	11412	2421	2725	1291
Frederico Westphalen	20,03	4,52	75,33	5,00	70479786	26744	3029	11136	6200
Vicente Dutra	20,03	4,52	75,33	5,00	3968674	6148	554	897	697
Ametista do Sul	20,03	4,52	75,33	5,00	3968674	7248	297	66	86
LAGOA VERMELHA	16,52	3,86	77,25	2,73	83509533	29810	4404	11788	5270
Santo Expedito do Sul	16,52	3,86	77,25	2,73	6550648	2720	47	12	24
Esmeralda	16,52	3,86	77,25	2,73	8708869	5559	798	1221	284
Muitos Capões	16,52	3,86	77,25	2,73	28954684	2836	233	386	37
Caseiros	16,52	3,86	77,25	2,73	8584106	2937	323	513	267
PASSO FUNDO	17,37	4,03	72,33	4,12	824253337	168440	29837	100957	66575
Coxilha	17,37	4,03	72,33	4,12	29690785	3041	599	645	368
Tapejara	17,37	4,03	72,33	4,12	52848225	15023	0	2	10

ANO: 2000

Município	TM	DPT	URAM	DPU	PIB	POP	PÚBL	RESID.	COML
							(Mwh)	(Mwh)	(Mwh)
Água Santa	17,37	4,03	72,33	4,12	23919853	4222	326	482	206
Ipiranga do Sul	17,37	4,03	72,33	4,12	16935640	2155	502	362	95
PELOTAS	17,78	4,29	81,08	4,34	868479238	323034	34031	182854	79937
São Lourenço do Sul	17,78	4,29	81,08	4,34	98198643	44008	3617	12606	5515
Turuçu	17,78	4,29	81,08	4,34	19979569	3722	96	605	175
Capão do Leão	17,78	4,29	81,08	4,34	72957826	23343	4568	8177	1177
Pedro Osório	17,78	4,29	81,08	4,34	15917233	8159	1036	3375	748
Cerrito	17,78	4,29	81,08	4,34	7161379	7005	455	1388	275
PORTO ALEGRE	19,25	4,27	76,25	3,70	8093925996	1360033	328379	1172563	1015465
Canoas	19,25	4,27	76,25	3,70	3853233260	304178	82514	194961	114514
Cachoeirinha	19,25	4,27	76,25	3,70	749581419	106306	20126	66284	33014
Gravataí	19,25	4,27	76,25	3,70	1062491211	228572	24763	138163	38994
Alvorada	19,25	4,27	76,25	3,70	138605790	180208	26374	80583	15703
Viamão	19,25	4,27	76,25	3,70	298909153	221724	10215	115940	23181
Esteio	19,25	4,27	76,25	3,70	692503449	79876	25845	52420	19138
RIO GRANDE	17,84	4,34	83,25	3,55	1165177879	186488	36987	119095	47628
São José do Norte	17,84	4,34	83,25	3,55	31180540	23802	1772	6157	1121
S. DO LIVRAMENTO	17,07	4,19	77,33	7,43	212902480	90747	17119	45271	20024
Dom Pedrito	17,07	4,19	77,33	7,43	164359014	40273	4860	19607	5186
SANTA MARIA	18,84	4,45	78,50	4,01	631797181	243396	47106	174678	76104
Restinga Seca	18,84	4,45	78,50	4,01	76352733	16486	4	19	3
Formigueiro	18,84	4,45	78,50	4,01	22743583	7751	590	1702	495
SÃO L. GONZAGA	20,14	4,46	70,83	5,78	76601911	243396	6344	16103	5993
Santo Ant.as Missões	20,14	4,46	70,83	5,78	25482022	13054	123	99	29
Dezesseis de Novembro	20,14	4,46	70,83	5,78	2514810	3535	368	290	112
Roque Gonzales	20,14	4,46	70,83	5,78	13578496	8037	934	1358	549
São Nicolau	20,14	4,46	70,83	5,78	7205777	6558	1049	1343	434
Pirapó	20,14	4,46	70,83	5,78	4487333	3472	273	301	119
STA. VIT. DO PALMAR	16,70	4,39	80,42	5,78	162182405	33296	2933	14206	3494
Chuí	16,70	4,39	80,42	5,78	22443910	4682	605	2984	3888
Jaguarão	16,70	4,39	80,42	5,78	72759198	30595	3434	14738	5228
TEUTÔNIA	18,80	4,22	79,83	4,22	188758536	22897	11	34	43
Colinas	18,80	4,22	79,83	4,22	11711085	2544	334	615	350
Paverama	18,80	4,22	79,83	4,22	17457875	7963	436	1026	410
Arroio do Meio	18,80	4,22	79,83	4,22	148021443	17186	1919	7450	3259
Lajeado	18,80	4,22	79,83	4,22	359782759	64775	9441	32184	25164
Estrela	18,80	4,22	79,83	4,22	183245867	28069	5376	15498	8252
Cruzeiro do Sul	18,80	4,22	79,83	4,22	48283334	12009	911	4307	1386
TORRES	18,89	4,13	83,67	3,82	68909542	30877	6881	26270	13687
Morrinhos do Sul	18,89	4,13	83,67	3,82	4449341	3705	415	491	337
Arroio do Sal	18,89	4,13	83,67	3,82	8611309	5175	2873	6983	2966

ANO: 2000

Município	TM	DPT	URAM	DPU	PIB	POP	PÚBL	RESID.	COML
							(Mwh)	(Mwh)	(Mwh)
Dom Pedro de Alcântara	18,89	4,13	83,67	3,82	3481446	2654	627	500	416
Três Cachoeiras	18,89	4,13	83,67	3,82	16822360	9855	1146	3741	1683
Terra de Areia	18,89	4,13	83,67	3,82	11808935	11764	1577	4182	1769
TRIUNFO	19,21	4,30	88,50	1,62	1828159787	6656	8515	6510	1847
Nova Santa Rita	19,21	4,30	88,50	1,62	141690737	15115	2231	8773	2695
Charqueadas	19,21	4,30	88,50	1,62	230802131	29798	10309	14841	4567
São Jerônimo	19,21	4,30	88,50	1,62	40015421	20514	1662	9286	3870
Taquari	19,21	4,30	88,50	1,62	197982401	26303	2961	11876	3926
Montenegro	19,21	4,30	88,50	1,62	320032766	54234	8127	31598	13008
Arroio dos Ratos	19,21	4,30	88,50	1,62	27079152	13390	1709	6576	1461
URUGUAIANA	18,33	5,03	76,92	5,79	418574841	126654	17894	71816	34585
Itaqui	18,33	5,03	76,92	5,79	275189166	39796	7128	20047	6284
Barra do Quaraí	18,33	5,03	76,92	5,79	32439534	3806	294	1306	846
Quaraí	18,33	5,03	76,92	5,79	57617713	24068	4008	11383	3979
Maçambará	18,33	5,03	76,92	5,79	38316668	5005	465	944	226
Alegrete	18,33	5,03	76,92	5,79	289264003	84769	12875	40453	13650

ANO: 2001

Município	TM	DPT	URAM	DPU	PIB	POP	PÚBL.	RESID.	COML
							(Mwh)	(Mwh)	(Mwh)
BAGÉ	18,30	4,00	79,58	3,90	246347055	115650	15860	57353	21769
Dom Pedrito	18,30	4,00	79,58	3,90	182009161	40600	4986	18913	5515
Lavras do Sul	18,30	4,00	79,58	3,90	20138758	8093	1265	2862	733
Hulha Negra	18,30	4,00	79,58	3,90	23286677	5250	87	143	6
Pinheiro Machado	18,30	4,00	79,58	3,90	71984954	13847	1588	4287	1066
Candiota	18,30	4,00	79,58	3,90	140913238	8313	1894	3420	1312
BENTO GONÇALVES	18,25	3,50	78,25	4,14	947258735	90564	20481	54342	35004
Nova Roma do Sul	18,25	3,50	78,25	4,14	25081221	3029	278	800	419
Monte Belo do Sul	18,25	3,50	78,25	4,14	13549348	2868	545	408	198
Nova Pádua	18,25	3,50	78,25	4,14	21936590	2396	167	463	348
Veranópolis	18,25	3,50	78,25	4,14	164363939	19684	4814	9972	6519
Antônio Prado	18,25	3,50	78,25	4,14	76441071	13111	1506	5127	2748
BOM JESUS	15,64	3,47	81,17	3,49	40747590	11919	1306	3762	1787
Jaquirana	15,64	3,47	81,17	3,49	6948053	4908	570	1120	215
Monte Alegre dos Campos	15,64	3,47	81,17	3,49	7499443	3109	549	190	50
Vacaria	15,64	3,47	81,17	3,49	237902393	57896	9676	25439	22950
CAMAQUÃ	18,87	3,46	84,58	5,52	270650068	60887	6195	24969	10691
Cristal	18,87	3,46	84,58	5,52	12406928	6670	957	1675	968
Chuívisca	18,87	3,46	84,58	5,52	14434207	4545	70	183	130
Dom Feliciano	18,87	3,46	84,58	5,52	28710251	13498	724	1239	650
Cerro Grande do Sul	18,87	3,46	84,58	5,52	23375497	8372	303	901	497

ANO: 2001

Município	TM	DPT	URAM	DPU	PIB	POP	PÚBL.	RESID.	COML
							(Mwh)	(Mwh)	(Mwh)
Sentinela do Sul	18,87	3,46	84,58	5,52	15482614	4955	294	946	264
CAMBARÁ DO SUL	15,64	3,25	83,08	3,85	55537243	6823	1053	2759	715
São José dos Ausentes	15,64	3,25	83,08	3,85	12227406	3133	367	689	129
São Francisco de Paula	15,64	3,25	83,08	3,85	42997761	19766	3893	7462	2976
CAMPO BOM	20,49	4,00	80,92	4,52	595683558	54643	15028	36472	14433
Novo Hamburgo	20,49	4,00	80,92	4,52	1457673093	238773	41304	169300	102242
Nova Hartz	20,49	4,00	80,92	4,52	108179126	15694	1371	8166	1817
Sapiranga	20,49	4,00	80,92	4,52	376491867	70581	6914	40426	15137
Araricá	20,49	4,00	80,92	4,52	9161338	4170	434	2288	755
Estância Velha	20,49	4,00	80,92	4,52	204882792	35861	3405	23460	8098
São Leopoldo	20,49	4,00	80,92	4,52	855856255	196267	31763	130121	74022
Sapucaia do Sul	20,49	4,00	80,92	4,52	831216297	124627	23327	67879	19554
Portão	20,49	4,00	80,92	4,52	194646055	25219	3756	14506	4481
CAXIAS DO SUL	17,77	3,32	79,08	3,90	3242631383	367185	61408	223412	140711
São Marcos	17,77	3,32	79,08	3,90	108831591	19280	3397	9457	4092
Nova Pádua	17,77	3,32	79,08	3,90	21936590	2396	167	463	348
Farroupilha	17,77	3,32	79,08	3,90	493933616	56206	9648	28520	17261
Flores da Cunha	17,77	3,32	79,08	3,90	216482868	24347	3311	10449	5264
Gramado	17,77	3,32	79,08	3,90	165261592	29264	4229	19799	18339
Canela	17,77	3,32	79,08	3,90	91963815	34628	11534	19085	10081
CRUZ ALTA	18,53	3,51	76,83	5,31	265028454	67522	13913	35730	16510
Pejuçara	18,53	3,51	76,83	5,31	40007339	4197	1169	1478	563
Ijuí	18,53	3,51	76,83	5,31	305082558	76128	1	4	2
ENCRUZILHADA DO SUL	18,19	3,71	79,67	4,79	29654329	24184	2302	6494	2145
Santana da Boa Vista	18,19	3,71	79,67	4,79	7182183	8640	611	1459	569
Caçapava do Sul	18,19	3,71	79,67	4,79	102165193	34572	4254	12540	4936
Pantano Grande	18,19	3,71	79,67	4,79	36231502	11105	1202	4071	2180
Cachoeira do Sul	18,19	3,71	79,67	4,79	225721768	87834	10087	40139	15073
IBIRUBÁ	19,09	3,80	80,33	4,08	113568214	18665	2293	7498	3314
Selbach	19,09	3,80	80,33	4,08	33137794	4864	78	175	45
Quinze de Novembro	19,09	3,80	80,33	4,08	27382075	3596	541	832	316
Tapera	19,09	3,80	80,33	4,08	47301505	10580	1753	4608	1890
Lagoa dos Três Cantos	19,09	3,80	80,33	4,08	15345819	1623	254	361	135
IRAÍ	21,22	3,88	76,33	7,83	20043106	9130	1136	2321	1259
Alpestre	21,22	3,88	76,33	7,83	8030664	10013	366	924	421
Planalto	21,22	3,88	76,33	7,83	16164252	11197	2376	2741	1367
Frederico Westphalen	21,22	3,88	76,33	7,83	70895330	26820	3034	11005	6416
Vicente Dutra	21,22	3,88	76,33	7,83	5218890	6075	570	969	500
Ametista do Sul	21,22	3,88	76,33	7,83	19610438	7501	318	68	145
LAGOA VERMELHA	17,20	3,67	78,67	4,83	89689310	28000	4366	11539	5039
Santo Expedito do Sul	17,20	3,67	78,67	4,83	6993221	2652	31	9	17

ANO: 2001

Município	TM	DPT	URAM	DPU	PIB	POP	PÚBL.	RESID.	COML
							(Mwh)	(Mwh)	(Mwh)
Esmeralda	17,20	3,67	78,67	4,83	13038572	3097	662	965	305
Muitos Capões	17,20	3,67	78,67	4,83	34581696	2909	245	390	71
Caseiros	17,20	3,67	78,67	4,83	10486733	2870	376	531	286
PASSO FUNDO	18,32	3,62	75,75	5,34	823718953	171013	29762	96646	64999
Coxilha	18,32	3,62	75,75	5,34	32447161	2979	579	688	353
Tapejara	18,32	3,62	75,75	5,34	62979896	14323	0	3	10
Água Santa	18,32	3,62	75,75	5,34	29602988	3813	322	485	225
Ipiranga do Sul	18,32	3,62	75,75	5,34	17035202	2023	489	364	96
PELOTAS	19,01	3,87	84,08	3,92	827256663	323834	34052	178560	80532
São Lourenço do Sul	19,01	3,87	84,08	3,92	90337015	43880	3650	12447	5984
Turuçu	19,01	3,87	84,08	3,92	21358225	3749	95	677	198
Capão do Leão	19,01	3,87	84,08	3,92	65381380	24226	4281	8107	1086
Pedro Osório	19,01	3,87	84,08	3,92	13785796	8132	964	3235	760
Cerrito	19,01	3,87	84,08	3,92	5362862	6612	454	1415	270
PORTO ALEGRE	20,63	3,78	77,08	4,38	7690038202	1371082	337427	1135166	1035036
Canoas	20,63	3,78	77,08	4,38	3748005421	309788	77729	192810	116369
Cachoeirinha	20,63	3,78	77,08	4,38	694019142	109526	20800	63950	33081
Gravataí	20,63	3,78	77,08	4,38	1323932155	238035	27379	133988	40410
Alvorada	20,63	3,78	77,08	4,38	157126451	188553	27556	77154	17989
Viamão	20,63	3,78	77,08	4,38	315192625	232457	10470	112115	24733
Esteio	20,63	3,78	77,08	4,38	730418443	80930	25191	52502	23922
RIO GRANDE	19,23	3,76	85,42	3,37	1139700429	187834	34295	98158	54691
São José do Norte	19,23	3,76	85,42	3,37	30854309	24103	1644	6397	1150
S. DO LIVRAMENTO	17,64	4,67	82,42	4,54	185250901	91845	16993	43545	20514
Dom Pedrito	17,64	4,67	82,42	4,54	182009161	40600	4986	18913	5515
SANTA MARIA	20,13	3,88	80,00	5,05	566543364	246681	48427	169149	77131
Restinga Seca	20,13	3,88	80,00	5,05	71608558	16493	4	21	4
Formigueiro	20,13	3,88	80,00	5,05	20843308	7565	573	1705	480
SÃO L. GONZAGA	21,10	3,92	74,25	5,34	106114156	36452	6223	15622	5978
Santo Ant. das Missões	21,10	3,92	74,25	5,34	33469210	12625	124	126	35
Dezesseis de Novembro	21,10	3,92	74,25	5,34	2469085	3385	380	279	104
Roque Gonzales	21,10	3,92	74,25	5,34	14896634	7681	893	1329	587
São Nicolau	21,10	3,92	74,25	5,34	7463962	6335	1003	1315	396
Pirapó	21,10	3,92	74,25	5,34	4450555	3295	236	322	126
STA. VIT. DO PALMAR	17,73	4,02	82,33	4,48	131716935	33387	2563	13663	3342
Chuí	17,73	4,02	82,33	4,48	18944590	5399	657	3070	3659
Jaguarão	17,73	4,02	82,33	4,48	61542153	30315	3439	13953	5131
TEUTÔNIA	20,15	3,79	79,67	4,81	221800823	21806	11	41	56
Colinas	20,15	3,79	79,67	4,81	11694840	2440	329	629	366
Paverama	20,15	3,79	79,67	4,81	19920276	7766	406	1041	467
Arroio do Meio	20,15	3,79	79,67	4,81	150651495	17144	1897	7643	3518

ANO: 2001

Município	TM	DPT	URAM	DPU	PIB	POP	PÚBL.	RESID.	COML
							(Mwh)	(Mwh)	(Mwh)
Lajeado	20,15	3,79	79,67	4,81	340462345	60857	10094	31387	25390
Estrela	20,15	3,79	79,67	4,81	177072803	27517	5256	15311	8487
Cruzeiro do Sul	20,15	3,79	79,67	4,81	46548878	11741	914	4342	1502
TORRES	20,28	3,59	86,08	1,51	65841068	31448	7103	27018	14199
Morrinhos do Sul	20,28	3,59	86,08	1,51	4077728	3510	436	412	213
Arroio do Sal	20,28	3,59	86,08	1,51	7708600	5533	2991	6683	2948
Dom Pedro de Alcântara	20,28	3,59	86,08	1,51	3420750	2661	677	461	423
Três Cachoeiras	20,28	3,59	86,08	1,51	14617090	9664	1258	3575	1724
Terra de Areia	20,28	3,59	86,08	1,51	11656098	8703	1317	3521	1606
TRIUNFO	20,34	3,66	86,67	4,85	1530801314	22643	8193	6312	1862
Nova Santa Rita	20,34	3,66	86,67	4,85	149978089	16510	2395	9190	2452
Charqueadas	20,34	3,66	86,67	4,85	241800637	30465	9851	14910	4671
São Jerônimo	20,34	3,66	86,67	4,85	48152578	20193	1657	9318	3943
Taquari	20,34	3,66	86,67	4,85	179697900	26118	2948	11702	4219
Montenegro	20,34	3,66	86,67	4,85	427991503	54962	7976	31706	13840
Arroio dos Ratos	20,34	3,66	86,67	4,85	23570524	13439	1720	6384	1495
URUGUAIANA	19,98	4,44	81,83	3,97	479745190	128151	18201	67687	33980
Itaqui	19,98	4,44	81,83	3,97	239565639	40047	7074	19031	6819
Barra do Quaraí	19,98	4,44	81,83	3,97	31922607	3955	342	1315	771
Quaraí	19,98	4,44	81,83	3,97	56775455	24130	3914	10989	3705
Maçambará	19,98	4,44	81,83	3,97	40423775	5092	462	954	229
Alegrete	19,98	4,44	81,83	3,97	242488314	84680	12984	37592	13807

ANO: 2002

Município	TM	DPT	URAM	DPU	PIB	POP	PÚBL.	RESID.	COML
							(Mwh)	(Mwh)	(Mwh)
BAGÉ	17,80	4,27	78,42	3,92	237464206	116361	121217	56849	21670
Dom Pedrito	17,80	4,27	78,42	3,92	192624338	40701	4993	18483	5262
Lavras do Sul	17,80	4,27	78,42	3,92	22177143	8136	1232	2803	743
Hulha Negra	17,80	4,27	78,42	3,92	23492215	5316	87	116	2
Pinheiro Machado	17,80	4,27	78,42	3,92	64332870	13984	1496	3979	1072
Candiota	17,80	4,27	78,42	3,92	142634987	8508	1912	3318	1383
BENTO GONÇALVES	17,98	3,63	78,00	3,74	903235043	94730	258554	53749	35278
Nova Roma do Sul	17,98	3,63	78,00	3,74	29027927	3032	309	797	423
Monte Belo do Sul	17,98	3,63	78,00	3,74	14582643	2861	570	423	214
Nova Pádua	17,98	3,63	78,00	3,74	24430105	2371	195	473	365
Veranópolis	17,98	3,63	78,00	3,74	206065421	19951	4651	10040	6278
Antônio Prado	17,98	3,63	78,00	3,74	77901030	13239	1720	4988	2667
BOM JESUS	15,49	3,33	81,33	2,46	36661756	11828	10216	3758	1837
Jaquirana	15,49	3,33	81,33	2,46	6475063	4993	526	1042	199
Monte Alegre dos Campos	15,49	3,33	81,33	2,46	7956570	3149	582	200	69

ANO: 2002

Município	TM	DPT	URAM	DPU	PIB	POP	PÚBL.	RESID.	COML
							(Mwh)	(Mwh)	(Mwh)
Vacaria	15,49	3,33	81,33	2,46	269249574	58497	9724	26557	26881
CAMAQUÃ	18,68	4,06	85,42	3,18	242022548	61578	113060	24308	10748
Cristal	18,68	4,06	85,42	3,18	18070907	6669	915	1617	1124
Chувиска	18,68	4,06	85,42	3,18	16528065	4626	84	219	106
Dom Feliciano	18,68	4,06	85,42	3,18	29339643	13851	707	1324	639
Cerro Grande do Sul	18,68	4,06	85,42	3,18	33937472	8516	303	962	557
Sentinela do Sul	18,68	4,06	85,42	3,18	12025139	5054	311	852	281
CAMBARÁ DO SUL	15,39	3,14	82,92	2,91	53743511	6837	13480	2863	814
São José dos Ausentes	15,39	3,14	82,92	2,91	10636764	3147	416	712	160
São Francisco de Paula	15,39	3,14	82,92	2,91	46831586	19851	3981	7342	3242
CAMPO BOM	20,13	4,26	81,33	4,66	595345159	55416	161730	37198	14730
Novo Hamburgo	20,13	4,26	81,33	4,66	1393342772	241949	43309	172494	111197
Nova Hartz	20,13	4,26	81,33	4,66	108541551	16410	1388	8348	1959
Sapiranga	20,13	4,26	81,33	4,66	374810273	72406	8572	41639	15013
Araricá	20,13	4,26	81,33	4,66	10853931	4375	485	2367	549
Estância Velha	20,13	4,26	81,33	4,66	215358601	36760	3598	24714	8002
São Leopoldo	20,13	4,26	81,33	4,66	833932431	199434	31857	120417	67023
Sapucaia do Sul	20,13	4,26	81,33	4,66	841697402	126708	27376	68569	19061
Portão	20,13	4,26	81,33	4,66	226369904	25809	3988	14756	4641
CAXIAS DO SUL	17,43	3,44	79,58	3,48	3262636142	373923	986316	227269	144289
São Marcos	17,43	3,44	79,58	3,48	116242308	19552	3238	9653	4020
Nova Pádua	17,43	3,44	79,58	3,48	24430105	2371	195	473	365
Farroupilha	17,43	3,44	79,58	3,48	480381347	56948	10063	28568	17841
Flores da Cunha	17,43	3,44	79,58	3,48	225365428	25091	3422	10536	5387
Gramado	17,43	3,44	79,58	3,48	128398221	30129	4050	20632	18559
Canela	17,43	3,44	79,58	3,48	88594512	35698	11839	19777	10181
CRUZ ALTA	18,13	3,43	79,00	4,61	227762337	67549	91954	34597	17044
Pejuçara	18,13	3,43	79,00	4,61	40356085	4200	1000	1418	535
Ijuí	18,13	3,43	79,00	4,61	304201733	76273	1	4	1
ENCRUZILHADA DO SUL	17,80	3,95	78,42	4,89	25156585	24534	17663	6612	2277
Santana da Boa Vista	17,80	3,95	78,42	4,89	8059166	8686	1063	1519	486
Caçapava do Sul	17,80	3,95	78,42	4,89	91486983	34457	4880	12035	4870
Pantano Grande	17,80	3,95	78,42	4,89	45808185	11274	1108	3908	2055
Cachoeira do Sul	17,80	3,95	78,42	4,89	205404003	87395	10846	39888	16305
IBIRUBÁ	19,11	4,04	82,08	4,83	114552823	18614	36958	7489	3371
Selbach	19,11	4,04	82,08	4,83	36323820	4850	66	180	48
Quinze de Novembro	19,11	4,04	82,08	4,83	24999842	3616	554	845	335
Tapera	19,11	4,04	82,08	4,83	56916764	10499	1877	4708	1875
Lagoa dos Três Cantos	19,11	4,04	82,08	4,83	13681253	1623	298	389	167
IRAÍ	20,18	3,98	79,08	4,76	17936567	9046	36958	2348	1376
Alpestre	20,18	3,98	79,08	4,76	8974828	9702	362	939	441

ANO: 2002

Município	TM	DPT	URAM	DPU	PIB	POP	PÚBL.	RESID.	COML
							(Mwh)	(Mwh)	(Mwh)
Planalto	20,18	3,98	79,08	4,76	16054844	11103	2147	2801	1416
Frederico Westphalen	20,18	3,98	79,08	4,76	77884022	26776	3046	11090	6585
Vicente Dutra	20,18	3,98	79,08	4,76	5285924	6054	636	987	472
Ametista do Sul	20,18	3,98	79,08	4,76	27134179	7551	327	27	78
LAGOA VERMELHA	17,33	3,52	79,42	4,19	80069467	28151	32957	11525	5181
Santo Expedito do Sul	17,33	3,52	79,42	4,19	7712774	2638	32	5	18
Esmeralda	17,33	3,52	79,42	4,19	13670618	3099	624	1053	367
Muitos Capões	17,33	3,52	79,42	4,19	48783972	2956	280	396	78
Caseiros	17,33	3,52	79,42	4,19	11675561	2897	397	507	274
PASSO FUNDO	18,48	4,24	76,08	4,44	771610287	173220	312941	96359	65813
Coxilha	18,48	4,24	76,08	4,44	38332740	2990	584	684	337
Tapejara	18,48	4,24	76,08	4,44	68818674	14537	0	1	9
Água Santa	18,48	4,24	76,08	4,44	33711598	3860	294	516	235
Ipiranga do Sul	18,48	4,24	76,08	4,44	17936127	1994	485	367	104
PELOTAS	18,58	4,14	84,25	3,44	713774576	327048	406895	174088	79064
São Lourenço do Sul	18,58	4,14	84,25	3,44	90818427	44159	3503	11923	6145
Turuçu	18,58	4,14	84,25	3,44	17530648	3843	129	622	218
Capão do Leão	18,58	4,14	84,25	3,44	58636265	24723	4592	7872	1172
Pedro Osório	18,58	4,14	84,25	3,44	17655928	8180	1031	3146	743
Cerrito	18,58	4,14	84,25	3,44	6800590	6933	495	1365	256
PORTO ALEGRE	20,16	4,07	77,42	4,64	7608214925	1383356	2847849	1107071	1033722
Canoas	20,16	4,07	77,42	4,64	3396216898	313946	78310	193994	116448
Cachoeirinha	20,16	4,07	77,42	4,64	670621882	111454	20163	63668	32782
Gravatá	20,16	4,07	77,42	4,64	1419783254	244324	27548	133015	41659
Alvorada	20,16	4,07	77,42	4,64	161723552	194440	28610	75557	18309
Viamão	20,16	4,07	77,42	4,64	378806097	238636	10458	107309	25764
Esteio	20,16	4,07	77,42	4,64	727952685	81499	27206	52971	24969
RIO GRANDE	18,70	4,10	85,08	3,32	1236857751	189123	355655	93621	54531
São José do Norte	18,70	4,10	85,08	3,32	31499912	24795	1690	6179	1080
S. DO LIVRAMENTO	18,13	5,05	82,08	5,00	171421650	93067	90667	43251	20254
Dom Pedrito	18,13	5,05	82,08	5,00	192624338	40701	4993	18483	5262
SANTA MARIA	19,84	4,30	79,67	5,76	582367306	249361	346735	171887	78933
Restinga Seca	19,84	4,30	79,67	5,76	76028852	16653	4	51	4
Formigueiro	19,84	4,30	79,67	5,76	23006434	7532	506	1774	478
SÃO L. GONZAGA	20,79	4,15	75,58	5,99	139665622	36259	55575	14764	5952
Santo Antônio das Missões	20,79	4,15	75,58	5,99	30035765	12472	137	154	44
Dezesseis de Novembro	20,79	4,15	75,58	5,99	2500184	3297	424	280	99
Roque Gonzales	20,79	4,15	75,58	5,99	14821944	7520	895	1197	552
São Nicolau	20,79	4,15	75,58	5,99	6205375	6218	978	1218	373
Pirapó	20,79	4,15	75,58	5,99	4750990	3230	199	325	118
STA. VIT. DO PALMAR	17,19	4,27	83,50	3,71	126090079	33413	63803	12720	3186

ANO: 2002

Município	TM	DPT	URAM	DPU	PIB	POP	PÚBL.	RESID.	COML
							(Mwh)	(Mwh)	(Mwh)
Chuí	17,19	4,27	83,50	3,71	21565651	5631	680	2970	3684
Jaguarão	17,19	4,27	83,50	3,71	54479820	30574	3268	12987	4675
TEUTÔNIA	20,04	4,15	78,50	6,97	193304746	22643	743	43	42
Colinas	20,04	4,15	78,50	6,97	12221258	2418	382	688	328
Paverama	20,04	4,15	78,50	6,97	25217019	7753	437	1108	507
Arroio do Meio	20,04	4,15	78,50	6,97	146112848	17319	1962	8023	3611
Lajeado	20,04	4,15	78,50	6,97	321674454	61944	10606	31882	25912
Estrela	20,04	4,15	78,50	6,97	233932578	27892	5101	15646	8906
Cruzeiro do Sul	20,04	4,15	78,50	6,97	48660558	11838	1008	4604	1584
TORRES	20,07	4,06	86,17	4,13	68677310	32146	61158	26455	13456
Morrinhos do Sul	20,07	4,06	86,17	4,13	4418711	3486	414	416	214
Arroio do Sal	20,07	4,06	86,17	4,13	7614521	5170	1108	6885	2818
Dom Pedro de Alcântara	20,07	4,06	86,17	4,13	3770133	2682	721	457	432
Três Cachoeiras	20,07	4,06	86,17	4,13	15724080	9827	1279	3923	1885
Terra de Areia	20,07	4,06	86,17	4,13	15984157	8819	1256	3443	1565
TRIUNFO	20,07	4,22	81,83	4,32	1780733991	23181	1136494	6274	1770
Nova Santa Rita	20,07	4,22	81,83	4,32	148097923	17426	2551	9283	2865
Charqueadas	20,07	4,22	81,83	4,32	245338595	30726	9718	14778	4627
São Jerônimo	20,07	4,22	81,83	4,32	38118895	20147	1628	9019	3730
Taquari	20,07	4,22	81,83	4,32	131280580	26261	3026	11626	4063
Montenegro	20,07	4,22	81,83	4,32	473055395	55551	7958	32180	13848
Arroio dos Ratos	20,07	4,22	81,83	4,32	22142500	13475	800	6257	1477
URUGUAIANA	19,66	4,94	79,17	5,54	501856154	129425	207790	66040	32407
Itaqui	19,66	4,94	79,17	5,54	231476977	40342	7147	18742	6368
Barra do Quaraí	19,66	4,94	79,17	5,54	32953233	4036	341	1350	756
Quaraí	19,66	4,94	79,17	5,54	56344038	24256	4099	10780	3790
Maçambará	19,66	4,94	79,17	5,54	40873969	5175	465	935	240
Alegrete	19,66	4,94	79,17	5,54	245956841	84969	13774	37076	13836

Milton Aluísio G. Araújo

Mestre em Sistemas de Informação e Apoio à Decisão pelo PPGA/EA/UFRGS, graduado em Engenharia Elétrica pela UFRGS, professor.

Interesses de pesquisa: Sistemas de informação e de apoio à decisão, pesquisa operacional, modelos preditivos.