

**UNIVERSIDADE FEDERAL DE SANTA CATARINA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA  
COMPUTAÇÃO**

**Sabrina Bet**

**APERFEIÇOAMENTO DE ALGORITMO GENÉTICO PARA  
SELEÇÃO DE VARIÁVEIS DE ENTRADA PARA REDE NEURAL  
PARA PREVISÃO DE CARGA ELÉTRICA ATIVA DE CURTO  
PRAZO**

Dissertação submetida à Universidade Federal de Santa Catarina como parte dos requisitos para a obtenção do grau de Mestre em Ciência da Computação

**Orientador: Raul Sidnei Wazlawick**

**Florianópolis, Julho de 2005**

**APERFEIÇOAMENTO DE ALGORITMO GENÉTICO PARA  
SELEÇÃO DE VARIÁVEIS DE ENTRADA PARA REDE NEURAL  
PARA PREVISÃO DE CARGA ELÉTRICA ATIVA DE CURTO  
PRAZO**

Sabrina Bet

Esta Dissertação foi julgada adequada para a obtenção do título de Mestre em Ciência da Computação Área de Concentração Sistema de Conhecimento e aprovada em sua forma final pelo Programa de Pós-Graduação em Ciência da Computação.

Banca Examinadora

---

Raul Sidnei Wazlawick, Dr. Eng.  
(Coordenador do Curso)

---

Raul Sidnei Wazlawick, Dr. Eng. (orientador)

---

Arlan Luiz Bettiol, DSA

---

Silvia Modesto Nassar, Dr.

---

Rogério Cid Bastos, Dr.

*“Que limites podemos impor a este poder, que age durante longas eras e escrutina rigidamente toda a constituição, estrutura e hábitos de cada criatura – favorecendo o que é bom e rejeitando o que é ruim? Não vejo limites a este poder de adaptar vagarosamente e maravilhosamente cada forma às mais complexas relações de vida”.*

CHARLES DARWIN, A Origem das Espécies

**Às duas novas vidas que estão por vir,  
Laura e Isabela.**

**Ao meu esposo, super companheiro de todas as  
horas.**

**À minha mãe, por entender que a educação é a  
única herança que ninguém pode roubar.**

## **AGRADECIMENTOS**

Primeiramente a Deus, por ter colocado em meu caminho, pessoas e oportunidades muito especiais. Sem elas eu não teria chegado aqui.

Ao meu orientador Raul, por todos os seus conselhos, importantíssimos para o meu crescimento pessoal e profissional. Com certeza um exemplo a ser seguido.

Aos integrantes do Projeto PCarga, Cláudio Magalhães de Oliveira, Luiz Ângelo D. de Luca, Gabriel da S. Beletti e Thiago N. de Holanda pelo tempo dispendido para o auxílio na realização deste trabalho. Vocês foram peças chaves nessa pesquisa.

Às Centrais Elétricas de Santa Catarina S.A. - CELESC, pela cessão de seu histórico de medições de potência ativa, temperatura ambiente e velocidade e direção do vento.

Ao Centro Integrado de Meteorologia e Recursos Hídricos de Santa Catarina – CLIMERH, pela cessão de seu histórico de medições das condições climáticas do Estado de Santa Catarina.

Ao Laboratório LABSOLAR (LABSOLAR/NCTS) da Universidade Federal de Santa Catarina, pela cessão de seu histórico de medições das condições climáticas da cidade de Florianópolis - SC.

Aos amigos, colegas e professores que encontrei durante esta jornada de dois anos, pois souberam me incentivar e muitas vezes me fizeram colocar os pés no chão.

# SUMÁRIO

<b>ÍNDICE DE FIGURAS</b> .....	<b>viii</b>
<b>ÍNDICE DE QUADROS</b> .....	<b>ix</b>
<b>ÍNDICE DE TABELAS</b> .....	<b>x</b>
<b>RESUMO</b> .....	<b>xi</b>
<b>ABSTRACT</b> .....	<b>xii</b>
<b>1 INTRODUÇÃO</b> .....	<b>1</b>
1.1 OBJETIVOS .....	6
1.2 JUSTIFICATIVA .....	7
1.3 METODOLOGIA.....	8
1.4 LIMITAÇÕES DO TRABALHO .....	10
1.5 ORGANIZAÇÃO DO TRABALHO .....	10
<b>2 FUNDAMENTOS DE INTELIGÊNCIA ARTIFICIAL</b> .....	<b>12</b>
2.1 REDES NEURAIS ARTIFICIAIS .....	13
2.1.1 <i>Arquitetura da Rede Função Base Radial</i> .....	14
2.2 ALGORITMOS GENÉTICOS.....	15
2.3 ALGORITMOS GENÉTICOS E REDES NEURAIS ARTIFICIAIS .....	18
<b>3 INTELIGÊNCIA ARTIFICIAL E PREVISÃO</b> .....	<b>19</b>
3.1 REDES NEURAIS ARTIFICIAIS .....	20
3.2 VARIÁVEIS DE ENTRADA .....	21
<b>4 PROJETO PCARGA</b> .....	<b>23</b>
4.1 MODELO PROPOSTO .....	23
4.2 PREVISOR ESPECIALISTA .....	25
4.2.1 <i>Previsor Neural Especializado</i> .....	26
4.2.2 <i>Modelador Evolutivo de 1ª Ordem</i> .....	27
4.3 O OBJETO DE ESTUDO DO PROJETO PCARGA .....	29
4.4 EXPERIMENTAÇÃO DO PROJETO PCARGA .....	30
<b>5 HIPÓTESE I - FUNÇÃO DE MUTAÇÃO EM GRUPO</b> .....	<b>31</b>
5.1 DELINEAMENTO DO EXPERIMENTO .....	31
5.2 DESCRIÇÃO DOS GRUPOS .....	32
5.3 RESULTADOS .....	34
5.4 CONCLUSÕES.....	37
<b>6 HIPÓTESE II – UTILIZAÇÃO DE SUBGRUPOS DE VARIÁVEIS CANDIDATAS</b> .....	<b>38</b>
6.1 DELINEAMENTO DO EXPERIMENTO .....	39
6.2 DESCRIÇÃO DOS EXPERIMENTOS.....	40
6.3 RESULTADOS .....	41
6.4 CONCLUSÕES.....	42

<b>7</b>	<b>CONSIDERAÇÕES FINAIS .....</b>	<b>44</b>
<b>8</b>	<b>REFERÊNCIAS .....</b>	<b>47</b>
<b>9</b>	<b>ANEXOS.....</b>	<b>50</b>
9.1	CLASSIFICAÇÃO DAS VARIÁVEIS DA FUNÇÃO DE MUTAÇÃO EM GRUPO.....	51
9.2	VALORES REFERENCIAIS .....	53

## ÍNDICE DE FIGURAS

<b>Figura 1</b> – Modelo elementar de Neurônio (MacCulloch & Pitts).....	14
<b>Figura 2</b> – Representação de um indivíduo como cromossomo.....	16
<b>Figura 3</b> – Esquema do Sistema de Previsão de Cargas .....	24
<b>Figura 4</b> – Esquema do Previsor Especialista do Sistema de Previsão.....	25
<b>Figura 5</b> – Representação Genética do Modelador Evolutivo de 1ª Ordem .....	28
<b>Figura 6</b> – Comparação das médias como referência ao Valor Crítico .....	35
<b>Figura 7</b> – Valores Médios e de Dispersão do Tempo de Convergência dos Experimentos .....	36
<b>Figura 8</b> – Deslocamentos das variáveis .....	40
<b>Figura 9</b> – Resumo das taxas de erro médio de erro (RMSE) dos experimentos.....	42



## ÍNDICE DE QUADROS

<b>Quadro 1</b> – Fluxo básico de um Algoritmo Genético.....	16
<b>Quadro 2</b> – Cálculo do Valor Crítico.....	34

## ÍNDICE DE TABELAS

<b>Tabela 1</b> – Comparação das Médias (RMSE) dos experimentos .....	34
<b>Tabela 2</b> – Comparação do tempo de convergência em número de gerações.....	36
<b>Tabela 3</b> – Comparação das Médias (RMSE-Treino) dos experimentos.....	41

## RESUMO

Este trabalho faz parte do Projeto PCarga, que tem como objetivo o desenvolvimento de um sistema previsor de carga elétrica ativa de curto prazo. O modelo, proposto por Oliveira (2004), visa a previsão de meia hora a frente em uma janela de uma semana, com a utilização de uma estrutura inteligente e adaptativa que se ajusta às características específicas de cada microrregião de consumo de energia elétrica e necessita de um baixo nível de intervenção humana. O modelo possui um modelador evolutivo que opera através de algoritmos genéticos e é responsável pela otimização do vetor das variáveis de entrada relevantes para a rede neural do sistema previsor.

A pesquisa aqui apresentada envolve a otimização deste algoritmo genético na tentativa de reduzir o seu tempo de convergência. Para tanto, foi realizado um trabalho envolvendo duas hipóteses. A primeira hipótese consiste em criar uma função de mutação simultânea em grupos específicos de variáveis, visando fazer com que o algoritmo tenha uma convergência mais rápida quando comparado ao método de mutação individual. Esta hipótese foi confirmada através de uma série de experimentos. A segunda hipótese trabalha com a idéia de redução do tamanho do cromossomo do algoritmo genético, através da eliminação de variáveis de deslocamento redundantes (valores absolutos e derivados). Neste caso, os experimentos realizados comprovaram a hipótese contrária, o que significa que a combinação de valores absolutos e derivados, ao invés da utilização de apenas um tipo destes valores, é fundamental para a boa qualidade das previsões da rede neural.

Palavras-chave: previsão de carga, inteligência artificial, algoritmos genéticos, redes neurais.

## ABSTRACT

This work is part of the PCarga Project, that intends to develop a very short time forecasting model for active bus load. The model, proposed by Oliveira (2004), aims to forecast half-an-hour forward in a one-week window using an intelligent and adaptive structure that adjusts itself to specific characteristics of each micro-region and requires little human intervention. The model has an evolving module based on a genetic algorithm that is responsible for optimizing the entry vector of the neural network for the forecast model.

The research presented here involves the improvement of this genetic algorithm, aiming to reduce its convergence time. Therefore, this work proposed two hypotheses. The first hypothesis is related to the creation of a simultaneous mutation function in specific groups of entries, allowing the algorithm to converge faster when compared to the approach with only individual mutation. This hypothesis has been confirmed through a series of experiments. The second hypothesis is related to the reduction of the size of the chromosome, by the elimination of redundant entries (absolute and derivated values). In this case, the experiments have confirmed the opposite hypothesis, which means that the combination of absolute and derivated values, rather than using just one kind, is fundamental for the quality of the forecasting model.

Key words: load forecasting, artificial intelligence, genetic algorithms, neural network.

# 1 INTRODUÇÃO

A energia elétrica possui algumas características especiais que a diferenciam de outros insumos industriais. Ela precisa ser gerada conforme a necessidade de consumo, pois não existe uma forma de armazenamento para tal insumo, e o excesso produzido é desperdiçado. Outra característica importante é seu meio de transporte, ou seja, não é realizado através dos meios usuais, tais como transporte rodoviário ou aéreo, mas através de redes elétricas (ANEEL, 2001).

Por parte do consumidor, a exigência em relação à qualidade da energia elétrica é bastante grande, pois esse é um insumo praticamente indispensável para a sociedade. Pode-se até mesmo considerar a energia elétrica como um produto básico para a sobrevivência, pois são incontáveis as atividades que necessitam deste bem. “Esta transformação, tem contribuído para o aumento da produtividade industrial e para o uso mais eficiente da energia elétrica, tornando mais rígidos os requisitos de qualidade da energia elétrica” (ANEEL, 2001), incluindo-se aí uma corrida pela competitividade. Porém, a qualidade da energia elétrica não depende apenas das concessionárias que a produzem, transmitem e distribuem, mas também do consumidor através do uso correto da energia.

Devido a essas características da energia elétrica e principalmente pela exigência de qualidade é preciso conhecer o consumo futuro de energia elétrica. Esse conhecimento irá contribuir de várias maneiras para os agentes envolvidos no processo, tais como órgãos públicos e privados, que atuam no setor de geração, transmissão e distribuição de energia elétrica. Isso, porque a previsão de carga engloba aspectos econômicos e de segurança, no intuito de permitir um fornecimento regular da energia elétrica, uma vez que possibilita o planejamento em curto e em longo prazo.

A previsão do comportamento do consumo da energia é feita em horizontes que podem variar de minutos até anos a frente. OLIVEIRA (1999) classifica os sistemas de previsão de acordo com o período abrangido, como sendo de curtíssimo, curto, médio e longo prazo. Assim, as previsões de curtíssimo prazo trabalham com o período de

poucos minutos até uma hora a frente; a previsão de curto prazo trabalha com uma janela de previsão de uma hora até uma semana a frente. A previsão de médio prazo, por sua vez, trabalha com uma janela de semanas ou meses a frente. E a previsão de longo prazo tenta prever anos a frente.

As previsões de curtíssimo prazo têm como objetivo auxiliar atividades de operação do sistema elétrico, como por exemplo, o despacho econômico e atividades de planejamento como o processo de manutenção. As previsões de curto prazo trabalham com as atividades de operação de manutenção e de planejamento de reserva. As previsões de médio prazo são utilizadas no planejamento da produção e intercâmbio de energia entre diferentes empresas de energia elétrica. E as previsões de longo prazo apóiam as atividades de planejamento estratégico de reserva e de expansão da capacidade de produção (METAXIOTIS, et al., 2003).

É um comportamento esperado que, à medida que se aumente o horizonte da previsão, a precisão dos modelos de previsão vá diminuindo de forma gradual, isso devido à necessidade de uso de previsões precedentes, sendo que até a previsão a médio prazo, trabalha-se com a previsão da curva da carga e a de longo prazo, com previsão da energia requerida (METAXIOTIS, et al., 2003).

Para uma aplicação ótima dos recursos do sistema de energia elétrica, portanto, os agentes necessitam de suporte para previsão. Este suporte pode ser suprido através de modelos matemáticos ou ferramentas computacionais que lhes permitam ter domínio sobre as informações referentes as variáveis do sistema elétrico.

Quanto aos métodos de Previsão, em especial de Cargas, eles podem ser classificados em duas categorias: métodos estatísticos (clássicos) e métodos de Inteligência Artificial.

Os métodos clássicos são baseados em métodos de modelagem estatística. Esses prevêm valores futuros de carga usando combinações matemáticas de valores prévios de carga e valores prévios e previstos de outras variáveis, tais como dados climáticos. Os métodos clássicos mais conhecidos usam regressão, entre eles, o modelo Box-Jenkins e os Filtros Kalman (METAXIOTIS, et al., 2003).

Cabe dizer que existe um grande desafio na utilização de métodos estatísticos para previsão de séries temporais, devido à presença da não-linearidade entre as variáveis, sendo que essas técnicas não são suficientemente robustas para este tipo de modelagem e não fornecem a precisão necessária para este tipo de previsão (SILVA, et al., 2001). Ocorre que o processo de previsão de energia elétrica requer a modelagem do relacionamento da carga elétrica com outras variáveis, tais como: condições climáticas (temperatura, umidade, velocidade do vento, radiação) e fatores sociais, como dia da semana, hora do dia e feriados, sendo este relacionamento bastante complexo, o que dificulta um mapeamento linear. E, nesse caso, a precisão é um fator muito importante, pois na previsão com horizonte além de um dia, existe ainda, o desafio do uso de previsões precedentes (DARBELLAY, et al., 2000).

As técnicas de Inteligência Artificial (IA) então vêm como um auxílio a esse problema, em especial, as técnicas de Redes Neurais, que ao longo dos anos vêm mostrando sua eficiência (METAXIOTIS, et al., 2003, DARBELLAY, et al., 2000, KHOTANZAD, et al., 1994), quando comparadas aos métodos estatísticos (ABU-EL-MAGD, et al., 2003). Os modelos de previsão iniciais apresentavam-se em uma única rede neural, e com o passar do tempo foram evoluindo para modelos modulares, seguidos de pesquisas com modelos híbridos<sup>1</sup>, que utilizam diversas técnicas de inteligência artificial em um único modelo. Dentre os sistemas híbridos, pode-se citar sistemas especialistas Fuzzy, integrado com redes neurais (TAMIMI, et al., 2000) e algoritmos genéticos, também integrados à redes neurais (LING, et al., 2003). E ainda, a combinação de redes neurais com Wavelet<sup>2</sup> (TAO, et al., 2002).

Sabe-se que os métodos de IA para previsão têm-se mostrado capazes de fornecer uma melhor performance quando trabalha com a não-linearidade da modelagem de séries temporais (METAXIOTIS, et al., 2003; SILVA, et al., 2001). E a vantagem da utilização de tecnologias como redes neurais está na habilidade dessas em modelar problemas com muitas variáveis. As redes neurais extraem o relacionamento não-linear implícito entre variáveis de entrada através do aprendizado dos dados de treinamento, ou seja, ela tem a capacidade de aprender através de exemplos.

---

<sup>1</sup> Modelos Híbridos em Ciências da Computação representa a combinação de técnicas de IA.

<sup>2</sup> Wavelet: normalmente utilizado para decompor uma série de carga em diferentes sub séries, as quais irão mostrar as diferentes frequências das características da carga.

Logo, a partir da necessidade de conhecer o comportamento futuro da carga, a CELESC (Centrais Elétricas de Santa Catarina), em parceria com a Universidade Federal de Santa Catarina, desenvolveu o projeto denominado PCARGA, que teve como objetivo desenvolver um sistema previsor de carga ativa de curto prazo.

O modelo, proposto por OLIVEIRA (2004), visa fazer a previsão de meia hora a frente em uma janela de uma semana. Propõe também, uma estrutura inteligente e adaptativa, capaz de ajustar-se às características específicas de cada microrregião de consumo de energia elétrica, adaptando-se à dinâmica de cada uma dessas microrregiões, necessitando de um baixo nível de intervenção humana (OLIVEIRA, 2004).

O modelo possui um Previsor Especialista responsável pela previsão de carga, o qual utiliza técnicas de redes neurais artificiais. Nesse módulo, as redes neurais são ajustadas através de algoritmos genéticos<sup>3</sup>, sendo esses responsáveis pela otimização do vetor das variáveis de entrada relevantes para a rede neural.

Nesse caso, o algoritmo genético é representado por uma cadeia de *bits*, chamada cromossomo, essa cadeia é composta por genes que representam o conjunto de variáveis candidatas para a entrada da rede neural, sendo que esse conjunto pode sofrer alterações com o tempo, de forma a agregar novas variáveis que possam ser consideradas relevantes ou eliminar as ineficientes. Dentre as variáveis candidatas, pode-se citar: carga, umidade, temperatura, velocidade do vento e radiação.

Para cada uma dessas variáveis, as quais são aqui denominadas “agora”, “semana” e “ano”, respectivamente, é possível estabelecer uma variação referente ao seu histórico, podendo-se trabalhar com dados do dia a ser previsto, de uma semana anterior e um ano antes. Para o processo de previsão, porém, os valores “agora” são usualmente os dados mais relevantes, pois são os últimos valores conhecidos.

Cada variável pode possuir ainda, uma série de valores e suas diferenciações, os quais são denominadas de variáveis de deslocamento, com um total de nove variações, onde os valores absolutos da série variam entre o momento zero, 30 minutos antes, 60

---

<sup>3</sup> Métodos de pesquisa e otimização inspirados na evolução natural e genética.



minutos antes, e 90 minutos antes, sendo que a diferença desses valores geram as diferenças de primeira ordem e, conseqüentemente, as diferenças de segunda ordem. O valor zero tem como referência o instante que está sendo previsto, sendo que o processo de previsão é repetido levando em consideração cada instante no intervalo de trinta minutos com a janela de uma semana.

Uma primeira hipótese foi feita em relação à convergência do algoritmo genético. O algoritmo, a partir de uma população inicial, reproduz novas populações, sendo que cada população, em média, é melhor que sua antecessora. Cada indivíduo passa por uma avaliação, na qual os indivíduos mais bem avaliados terão mais chances de serem selecionados para formar uma nova geração (reprodução). Existe então, uma probabilidade  $P$  desses indivíduos selecionados passarem por um *crossover* (cruzamento), que representa a troca de códigos genéticos entre um par de indivíduos a partir de um ponto de corte nos cromossomos e ainda, a probabilidade da ocorrência de uma mutação.

Esse processo de reprodução, após uma série de interações, tende a um equilíbrio estático. Nesse caso, a mutação tende a quebrar esta estacionaridade, incorporando aspectos de criatividade no algoritmo genético (WAZLAWICK, 1993). Desse modo, se a mutação não gerar um bom resultado (*fitness*), a probabilidade de reprodução será consideravelmente pequena, contudo, sendo ele bom, poderá trazer mudanças radicais no processo de busca da solução. Esta é uma grande vantagem do algoritmo genético, pois o mecanismo de mutação pode levar a resultados, que possivelmente não eram esperados.

De acordo com isso, uma função de mutação em grupo para o sistema de previsão poderia influenciar positivamente na convergência para a solução. Essa função poderia fazer com que grupos inteiros de variáveis, (por exemplo, todos os valores de umidade) pudessem ser desativados de uma só vez ao invés de se realizar este trabalho pontualmente, fazendo com que a solução convergisse para um resultado melhor, caso esse grupo de variáveis realmente não tenha relevância para o sistema. Portanto, é necessário fazer uma identificação de grupos que possam influenciar no processo de convergência do algoritmo genético.

Também pode-se perceber que o número de variáveis candidatas é bastante extenso, tendo em vista que para cada variável existe a possibilidade de 27 valores (as nove variações contempladas nos três períodos possíveis – agora, semana, ano). Logo, a inclusão de uma nova grandeza no algoritmo genético acarretaria a inclusão de 27 novos valores, o que torna mais longo o tempo total da evolução do algoritmo.

Como hipótese, acredita-se que a redução do número de variáveis candidatas no algoritmo genético pode melhorar a precisão e eficiência do processo de previsão. Pensando nisso, uma possibilidade de corte de variáveis está nas variáveis de deslocamento, para o que é necessário um estudo sobre a relevância delas na previsão. Esta hipótese prevê que possa existir uma combinação padrão de variáveis que possa ser usada como entrada para a rede neural, e que apresente sempre melhores resultados do que outras combinações. Conforme demonstrado adiante, esta hipótese foi refutada e sua hipótese oposta é que foi comprovada com confiança de 95%.

É válido observar que a maioria dos trabalhos encontrados na literatura utiliza somente valores absolutos das variáveis, porém, os valores das derivadas auxiliam no processo de estacionaridade, pois possibilitam a identificação de uma tendência linear. Para Silva et al (2001), os valores das derivadas, para algumas variáveis, podem ser tão importantes quanto os valores absolutos.

## **1.1 Objetivos**

O objetivo geral deste trabalho é investigar a redução do tempo de convergência do algoritmo genético utilizado na seleção de variáveis de entrada para as redes neurais do sistema de previsão de cargas, baseado no sistema de previsão anterior.

Os objetivos específicos são:

- a) Investigar a hipótese de que a função de mutação em grupo permite uma convergência mais rápida da solução sem perda de qualidade.

- b) Investigar a hipótese da existência de subgrupos de variáveis candidatas relevantes, reduzindo assim, o tamanho do vetor de variáveis candidatas, possibilitando a diminuição do tempo de convergência do algoritmo genético.

Nesse sentido, a hipótese da função de mutação em grupo foi confirmada, possibilitando uma convergência mais rápida da solução e melhorando a qualidade da previsão.

Por outro lado, a hipótese da existência de subgrupos de variáveis candidatas não foi confirmada, ou seja, confirmou-se que, visando obter resultados satisfatórios com a função de previsão, não é vantajoso trabalhar apenas com um subconjunto de variáveis de deslocamento. Tal demonstração confirma a suposição inicial do projeto PCarga de que a qualidade da previsão pode ser melhorada quando se permite ao algoritmo genético escolher o conjunto de variáveis de entrada, ao invés de defini-las com antecedência.

## **1.2 Justificativa**

Conforme se sabe, a precisão e baixo tempo de resposta em um sistema de previsão de curto prazo é essencial. Baseado nesta afirmação, este trabalho pretende dar uma contribuição para o projeto PCarga, desenvolvido em parceria com a Universidade Federal de Santa Catarina e CELESC, que tem como objetivo a criação de um sistema previsor de carga ativa de curto prazo, proposto por OLIVEIRA (2004).

A partir desta necessidade, os objetivos desta pesquisa envolveram hipóteses de trabalho que visavam possibilitar uma melhoria de desempenho do modelo. Uma dessas possibilidades estava no algoritmo genético utilizado no modelo como otimizador das variáveis de entrada para a rede neural, responsável pela previsão. Foram então verificadas duas possíveis hipóteses de trabalho.

A hipótese da função de mutação em grupo surgiu devido à análise dos experimentos, nos quais foi observado que em algumas situações, grandes grupos de variáveis de entrada eram deixados de fora ou incluídos na rede neural. O processo de

mutação individual, por sua vez, não leva em consideração esta situação. Por exemplo, existem 27 variáveis referentes à umidade; se ela não for uma grandeza relevante para a previsão, nenhuma destas variáveis será relevante. Desse modo, para que o algoritmo genético pudesse testar essa simples hipótese, ele poderia levar centenas ou milhares de gerações até que todas essas variáveis fossem desativadas. Com a função de mutação em grupo, todas as variáveis referentes à umidade podem ser desligadas de uma única vez e, assim, a hipótese de que a umidade não é relevante pode ser testada de uma geração para outra.

Já a segunda hipótese deste trabalho teve como motivação o fato de que as variáveis de deslocamento podem, em alguns casos, ser derivadas umas das outras, gerando informações redundantes. Por exemplo, a derivada atual pode ser encontrada a partir do valor absoluto atual e do valor absoluto anterior; o valor absoluto anterior pode ser encontrado a partir do valor absoluto atual e da derivada atual. Essa redundância é inicialmente colocada no cromossomo para que o algoritmo genético encontre a melhor combinação de variáveis. Porém, quanto maior o cromossomo, maior tende a ser o tempo de convergência do algoritmo. Logo, a hipótese de que seria possível trabalhar apenas com valores absolutos ou apenas com derivadas foi testada. Inicialmente, tentou-se demonstrar que essa simplificação poderia manter a qualidade dos resultados ao mesmo tempo em que diminuiria o tempo de convergência. Mas foi confirmada exatamente a hipótese contrária, ou seja, a eliminação das redundâncias piora significativamente o resultado das previsões.

Como dito anteriormente, a maioria dos trabalhos encontrados na literatura utiliza somente valores absolutos das variáveis. Entretanto, em seu modelo, Oliveira (2004) propõe o uso de valores de diferenciação e absolutos, que para Silva (2001) podem ser tão importantes quanto os valores absolutos.

### **1.3 Metodologia**

Após o levantamento das duas hipóteses, anteriormente apresentadas, o trabalho foi dividido em duas etapas.

A primeira etapa do trabalho envolveu a comprovação da hipótese de que a função de mutação em grupo permitiria uma convergência mais rápida do algoritmo genético. Em um primeiro momento, foi realizada uma análise das variáveis para a identificação dos grupos candidatos para a função de mutação em grupo. A partir desse ponto, foram realizados experimentos para verificar a influência da nova função na convergência do algoritmo genético e melhora dos resultados de previsão, sendo feita uma análise dos resultados para comprovação da hipótese.

Nessa etapa foram realizados quatro tipos de experimentos com um total de 10 repetições com o algoritmo genético em 2000 gerações. O tempo médio de processamento dos experimentos foi de 2 dias (48 horas), de forma que o período de experimentação dessa etapa tomou cerca de 2 meses.

A segunda etapa envolveu a hipótese da existência de subgrupos de variáveis candidatas. Para sua comprovação foram realizados experimentos utilizando combinações de variáveis julgadas representativas, na tentativa de validar a suposição de que com essas combinações os resultados seriam tão bons quanto a versão que utiliza uma combinação de todas as variáveis de deslocamento simultaneamente, ao mesmo tempo em que a convergência do algoritmo genético se tornaria mais rápida. Essa hipótese não foi comprovada, verificando-se que existe a necessidade da utilização de todas as variáveis, a fim de se obter resultados satisfatórios.

Nesta etapa foram realizados três tipos de experimentos aplicados em dois pontos distintos e em três estações do ano, sendo realizadas três repetições para cada tipo de experimento, somando-se um total de 54 repetições com o algoritmo genético em 2000 gerações. O tempo médio de processamento dos experimentos foi reduzido para 36 horas, devido a uma redução feita no número de gerações do algoritmo genético. Diante disso, o período para realização da experimentação dessa etapa foi aproximadamente um mês e meio.

Nas duas etapas os experimentos foram realizados utilizando o processamento paralelo do algoritmo genético, sendo que os equipamentos utilizados variam desde AMD Duron 700 Mhz até processadores Intel Pentium de 2,4Ghz. Todos os computadores acima de 128MB de memória RAM.

Para validação das hipóteses, os experimentos realizados nas duas etapas possuem as mesmas configurações definidas por conjuntos de experimentos do PCarga, sendo que para a primeira etapa o diferencial dos experimentos foi a inclusão da função de mutação em grupo e na segunda etapa, a utilização das combinações identificadas. Permanecendo as outras configurações inalteradas, facilitou-se o processo de comparação de experimentos e validação, através de testes de hipóteses estatísticos. Foi utilizado o teste t com uma amostra de mesmo tamanho, e o nível de significância adotado foi de 5%.

## **1.4 Limitações do Trabalho**

As limitações deste trabalho envolveram principalmente as etapas de experimentações.

Na etapa I não foi possível efetivar a realização de experimentos que permitissem um estudo mais detalhado da influência do tipo de mutação a ser aplicada aos grupos, tais como a desativação, a ativação e a inversão de valores da mutação. Poderia-se, por exemplo, ter experimentado trabalhar apenas com a desativação de grupo, ou com a ativação e a inversão. Como esse estudo não foi feito, optou-se por trabalhar com os três tipos de mutação, os quais foram selecionados aleatoriamente pelo algoritmo genético.

Na etapa II não foi possível a realização de experimentos de todas as combinações possíveis das variáveis de deslocamento, sendo escolhidas apenas três combinações julgadas representativas: apenas valores absolutos, apenas derivadas de primeira ordem e apenas derivadas de segunda ordem.

## **1.5 Organização do Trabalho**

Este trabalho está organizado em sete capítulos. O capítulo 1 apresenta uma breve introdução ao tema, bem como as hipóteses que serão trabalhadas, os objetivos, as justificativas, a metodologia de trabalho e limitações.

No capítulo 2 são apresentados os conceitos básicos de inteligência artificial, especialmente Redes Neurais Artificiais e Algoritmos Genéticos, pois são esses os mecanismos utilizados do modelo de previsão construído para a validação das hipóteses deste trabalho.

O capítulo 3 apresenta uma revisão bibliográfica sobre a utilização das técnicas de inteligência artificial para previsão.

No capítulo 4 é feita a descrição do modelo de previsão proposto por Oliveira (2004), sobre o qual este trabalho se fundamenta.

Os capítulos 5 e 6 descrevem as experimentações realizadas para comprovação das hipóteses 1 e 2 respectivamente. Assim como a análise dos resultados e conclusões acerca dos mesmos.

Por fim, o capítulo 7 apresenta as considerações finais referentes ao trabalho, bem como sugestões de trabalhos futuros.

## 2 FUNDAMENTOS DE INTELIGÊNCIA ARTIFICIAL

O campo da inteligência artificial (IA) tem sua inspiração em pensamentos filosóficos, psicológicos e biológicos, e vai além, haja vista que “tenta não apenas compreender, mas também construir entidades inteligentes” (RUSSEL & NORVIG, 2004).

Pode ser considerada uma ciência bastante recente se comparada a outras ciências como filosofia e matemática, pois apenas em 1956, após a Segunda Guerra Mundial, teve seu nome cunhado por John McCarthy em um encontro com os primeiros pesquisadores da área no Dartmouth College.

Inicialmente, era dividida em dois paradigmas: Simbólico e Conexionista. A Inteligência Artificial Simbólica (IAS) trabalha com o comportamento global, sem preocupar-se com os mecanismos responsáveis por esse comportamento. Já a Inteligência Artificial Conexionista (IAC), “reúne modelos computacionais da IA e técnicas experimentais da psicologia para tentar construir teorias precisas e verificáveis a respeito dos processos de funcionamento da mente humana” (RUSSEL & NORVIG, 2004), ou seja, trata da construção de máquinas que imitam a estrutura do cérebro humano.

Neste capítulo será abordado o paradigma conexionista, através da fundamentação básica de Redes Neurais Artificiais, que são sistemas baseados na neurociência<sup>4</sup>, e de algoritmos genéticos, do ponto de vista evolucionário, que são sistemas de busca e otimização baseados no processo genético da evolução natural. Estando nesses dois elementos, as redes neurais artificiais e os algoritmos genéticos, a fundamentação do mecanismo de previsão construído e utilizado para a validação das hipóteses deste trabalho.

---

<sup>4</sup> Estudo do Sistema Nervoso, do cérebro em particular.



## 2.1 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são representações computacionais do funcionamento do cérebro humano, mais especificamente, dos neurônios.

Um esquema simples do neurônio consiste no desenho de um corpo celular com várias ramificações chamadas de dendritos e de um ramo chamado axônio. Os dendritos recebem sinais de outros neurônios. Esses impulsos recebidos podem ativar o neurônio, o que o faz disparar um impulso através do axônio, formando sinapses com os dendritos de outros neurônios. Essas sinapses formam o contato entre os neurônios e podem agir de forma inibitória ou excitatória, ou seja, diminuindo ou aumentando o sinal. Assim, o conjunto de neurônios conectados através de sinapses é que forma as redes neurais (LUGER, 2004).


Cabe dizer que a intenção de criar as Redes Neurais Artificiais centra-se na simulação de um sistema capaz de aprender e assimilar.

As RNAs possuem a vantagem de trabalhar com problemas mal definidos, ou seja, problemas onde não se tem um conhecimento explícito do funcionamento das tarefas, o que impossibilita a criação de algoritmos para solução. O conhecimento das RNAs é construído através de exemplos, pelos quais a rede pode fazer novas deduções, evoluindo o seu aprendizado e aumentando ou reduzindo a força das conexões entre os neurônios.

LUGER (2004) e FERNANDES (2003) descrevem o neurônio artificial (Figura 1), sendo composto de: *sinais de entrada* ( $x_i$ ), que são os dados vindos do ambiente ou de outros neurônios; *conjunto de pesos* com valor real ( $w_i$ ) que descrevem as forças de conexão; *nível de ativação* ( $\sum w_i x_i$ ); *função de limiar* ( $f$ ) que calcula o estado de saída ( $y$ ), produzindo ou não um sinal.

As Redes Neurais Artificiais são compostas por três camadas, conhecidas como: *camada de entrada*, que recebe os sinais que serão utilizados pela rede; *camada intermediária*, onde é feito o processamento da rede através de conexões ponderadas entre os neurônios; *camada de saída*, que retorna um sinal de saída como resposta. Elas

possuem ainda, algumas propriedades globais, tais como: *topologia da rede* que define a forma de conexões entre os neurônios individuais e o *algoritmo de aprendizagem*.



**Figura 1 – Modelo elementar de Neurônio (MacCulloch & Pitts)**

Fonte: FERNANDES (2003)

Entre as camadas da rede existem conexões e pesos associados a cada uma conexão. Esses pesos são ajustados através de algoritmos de aprendizagem, que extraem regras a partir dos exemplos. Os modelos neurais trabalham com camadas compostas por diversos neurônios, permitindo um mapeamento não-linear das regras.

A seguir é feita uma breve descrição do modelo de rede Função de Base Radial e uma introdução aos algoritmos genéticos, na seqüência, uma abordagem acerca da utilização dos algoritmos genéticos com as redes neurais artificiais.

### **2.1.1 Arquitetura da Rede Função Base Radial**

Segundo Russel & Norvig (2004) os modelos de redes de função base radial ou RBF (*radial basis function*) são os mais populares. Este modelo realiza aproximação de funções.

As redes RBF podem ser treinadas em duas fases, sendo que na primeira fase as funções são apontadas por técnicas não supervisionadas, e a segunda fase os pesos são métodos lineares supervisionados (RUSSEL & NORVIG, 2004; BISHOP, 1997).

A arquitetura da RBF é de múltiplas camadas, sendo que, sua forma mais básica é de três camadas. Na camada intermediária o espaço de entrada é transformado, de maneira não linear em um espaço de maior dimensão, e os nodos da camada de saída formam uma combinação linear das funções de base radial que são calculados pelos

nodos da camada intermediária, tendo esses nodos a dimensão do vetor de saída desejado (TODESCO, et al., 2004). Por isso, as RBF's possuem um aprendizado mais rápido (BISHOP, 1997; TODESCO, et al., 2004), e são capazes de operar em tempo de real (BISHOP, 1997).

## 2.2 Algoritmos Genéticos

Os Algoritmos Genéticos são técnicas de busca utilizadas em problemas que envolvem maximização e minimização, sendo objetivo dessas otimizar uma solução. Têm como base teórica o processo de seleção natural<sup>5</sup> e a genética.

O seu potencial está na utilização de um processamento naturalmente paralelo, onde cada segmento genético é representado como uma unidade independente de solução. Nesse caso, o processo de busca é realizado em uma população de soluções e não apenas baseado numa única solução (LUGER, 2004).

As populações de indivíduos passam por um processo de evolução e a exemplo da seleção natural, certos indivíduos terão melhores chances de sobrevivência, produzindo indivíduos mais aptos, baseados nas necessidades do meio ambiente e da própria população.

É válido lembrar que a evolução inspirada na genética utiliza processos de seleção e de cruzamento de indivíduos, que resulta em novos indivíduos, e conta ainda com a existência de mutações no desenvolvimento das gerações.


De acordo com isso, LUGER (2004) apresenta três estágios distintos na solução de um problema utilizando-se algoritmos genéticos: no primeiro, as soluções potenciais do domínio do problema são codificadas, freqüentemente em cadeias de *bits*; no segundo estágio, algoritmos de acasalamento e mutação produzem novas gerações de indivíduos; ocorrendo no último estágio o julgamento de quais indivíduos são as “melhores” soluções para o problema em questão.

---

<sup>5</sup> Teoria de Charles Darwin.

Considerando que o algoritmo genético como modelo computacional é a representação do modelo biológico, ele apresenta as soluções como uma população de indivíduos onde cada indivíduo é representado por cadeias de um alfabeto, sendo que a seqüência de *bits* é a forma mais utilizada (0 e 1).

Desse modo, cada cadeia de *bit* corresponde a um cromossomo e cada elemento do cromossomo é equivalente a um gene. Ao alfabeto denomina-se alelo. Desta forma, cada indivíduo da população é representado por um cromossomo (Figura 2).

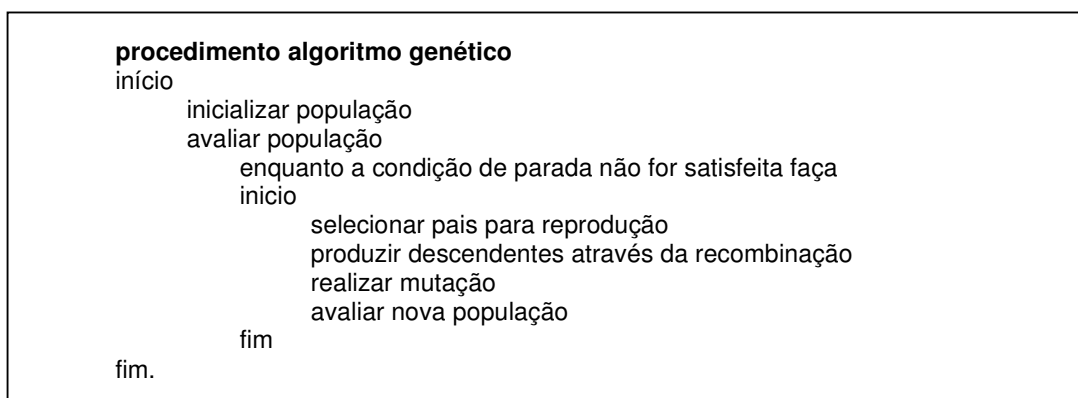


**Figura 2 – Representação de um indivíduo como cromossomo**

Para a evolução dos cromossomos são utilizados operadores genéticos como o de seleção, reprodução ou recombinação e mutação. Os operadores genéticos atuam com valores probabilísticos, tornando a solução do problema não determinística.

Uma função de avaliação ou função de aptidão avalia cada solução encontrada, atribuindo ao indivíduo um grau de aptidão ou *fitness*.

O Quadro 1 apresenta o fluxo básico do algoritmo genético, sendo que, implementações específicas particularizam esta estrutura.



**Quadro 1 – Fluxo básico de um Algoritmo Genético**

Fonte: Adaptação de LUGER (2004); RUSSEL & NORVIG (2004)

Segundo o esquema, o procedimento inicial do algoritmo genético é a inicialização da população, onde geralmente, é feita a seleção de  $n$  indivíduos de forma aleatória. O próximo passo é a avaliação de cada um dos indivíduos criados nesse procedimento inicial, atribuindo um valor de *fitness*.

Assim, o algoritmo entra em um laço de repetição até que algum critério de parada seja satisfeito. O critério de parada ideal seria o término do algoritmo tão logo o ponto ótimo fosse encontrado, porém, quando se trabalha com algoritmos genéticos, dificilmente conhece-se tal ponto. Por isso, os critérios de parada mais utilizados são o tempo limite de processamento ou o número máximo de gerações. Um outro critério usado se faz quando o algoritmo entra em estagnação, ou seja, não se observa mais melhoria das populações ao longo das gerações (LUGER, 2004).

Prosseguindo, a partir de uma população criada é feita uma seleção de indivíduos para continuar na próxima geração. Esta seleção é frequentemente probabilística e os indivíduos com maior grau de *fitness* têm maiores probabilidades de serem selecionados, haja vista que indivíduos mais fracos recebem menores probabilidades de seleção, mas não são diretamente eliminados. Isso faz com que indivíduos menos aptos tenham chance de sobrevivência, uma vez que podem conter algum componente essencial para a solução do problema, não sendo interessante eliminá-los de imediato.

Já a recombinação de indivíduos, também conhecida como *crossover*, seleciona dois indivíduos candidatos para a próxima geração e faz a troca de fragmentos entre eles, gerando dois novos indivíduos. A seleção dos pais e o ponto de corte a partir do qual os fragmentos irão gerar os novos indivíduos ocorre com valores probabilísticos.

Outra operação genética muito importante é a mutação, pois ela permite que sejam feitas alterações no código genético de um único indivíduo. Esta operação possibilita incrementar um indivíduo com um componente excluído durante a seleção inicial da população, e também tende a quebrar a estacionaridade da evolução, nos momentos que o algoritmo entra em um equilíbrio estático. Se a mutação não gerar bons resultados, o *fitness* do novo indivíduo não permitirá que o mesmo prossiga por muitas gerações, porém, ela pode levar a bons resultados possivelmente não esperados (WAZLAWICK, 1993).

Também é necessário considerar que a existência de um valor de probabilidade muito alto para a ocorrência da mutação pode não permitir a convergência para uma solução, e um valor muito baixo, pode estabilizar a população em num mínimo local, deixando de explorar todos os espaços de possibilidades. Assim, a probabilidade de mutação deve variar conforme as necessidades do problema.

### **2.3 Algoritmos Genéticos e Redes Neurais Artificiais**

Há uma variedade de aplicações que envolvem algoritmos genéticos e redes neurais artificiais.

GRUAU & WHITLEY (1993) apresentam algumas dessas combinações onde o algoritmo genético é utilizado para incrementar as redes neurais, sendo elas:

- o treinamento dos pesos para o aprendizado das RNAs;
- a seleção dos dados de treinamento e interpretação do comportamento de saída das redes neurais;
- a busca de arquiteturas de redes neurais.

Este trabalho, portanto, utiliza o algoritmo genético no escopo de seleção de variáveis de entrada para o treinamento da rede neural artificial.

### 3 INTELIGÊNCIA ARTIFICIAL E PREVISÃO

A Inteligência Artificial (IA) é uma ferramenta poderosa e flexível que vem oferecendo meios para a solução de problemas, que muitas vezes não podem ser resolvidos por outros métodos ou então, são resolvidos de forma bem mais prática e veloz por ela. A IA é cada vez mais aplicada em diversas áreas da vida social e vem influenciando muito o processo de tomada de decisão (METAXIOTIS, et al., 2003).

Um dos campos onde a inteligência artificial ganhou espaço foi o de previsão, sendo tratada mais especificamente neste estudo a área de previsão de cargas. A IA vem gradualmente substituindo ou aprimorando os métodos clássicos de previsão, os quais são baseados em modelagem estatística e utilizam, entre outras técnicas, regressão, modelos Box-Jenkins e filtros Kalman, usando basicamente combinações matemáticas de valores prévios e correntes de carga, além de outras variáveis de dados climáticos.

O motivo dessa substituição ocorre devido à necessidade de previsão envolvendo variáveis de séries temporais, que é o caso da previsão de cargas, pois existe a presença de não-linearidade entre as variáveis. Característica essa que faz com que os modelos clássicos não sejam suficientemente robustos para a modelagem, pois não oferecem a precisão requerida para este tipo de previsão (SILVA, et al., 2001).

A precisão é um fator importante na previsão de cargas, uma vez que em previsões com horizontes além de um dia, existe ainda o desafio do uso de cadeias de previsões precedentes (DARBELLAY, et al., 2000).

Nesse sentido, a IA dispõe de técnicas que têm a capacidade de realizar essa modelagem de séries temporais, com presença de não-linearidade, apresentando um bom nível de eficiência (METAXIOTIS, et al., 2003; DARBELLAY, et al.; 2000; KHOTANZAD, et al., 1994; SILVA, et al., 2001), principalmente em comparação às técnicas clássicas (ABU-ELMAGD, et al., 2003).

Dentre as possibilidades, a técnica mais utilizada para esse fim é a das Redes Neurais Artificiais (METAXIOTIS, et al., 2003, DARBELLAY, et al., 2000;

KHOTANZAD, et al., 1994), pois elas têm a habilidade de modelar problemas com muitas variáveis sem fazer suposições de dependência entre variáveis de entrada. As redes neurais extraem o relacionamento não-linear implícito entre variáveis de entrada, através do aprendizado dos dados de treinamento, ou seja, ela tem a capacidade de aprender através de exemplos.

O uso inicial da IA se deu com a utilização das Redes Neurais Artificiais, em 1964, com a rede linear adaptativa de Widrow para previsão do tempo. Os modelos de previsão iniciais apresentavam-se em uma única rede neural, evoluindo para modelos modulares, seguidos de pesquisas com modelos híbridos, que utilizam diversas técnicas de inteligência artificial em um único modelo (OLIVEIRA, 2004).

### **3.1 Redes Neurais Artificiais**

A introdução das Redes Neurais Artificiais (RNAs) na previsão de carga de curto prazo ocorreu em 1990 (METAXIOTIS, et al., 2003), sendo que o principal motivo da utilização dessas deve-se à capacidade que possuem de realizar modelagem de relacionamentos não-lineares entre as camadas de entrada e saída e, principalmente, pela capacidade de aprendizado através de exemplos que detém.

Não existe uma padronização para a escolha de uma arquitetura da Rede Neural Artificial para a previsão de cargas. A construção e ajuste dos modelos são realizados a partir de necessidades particulares.

Conforme MICHANOS, et al. (2003), as arquiteturas de Redes Neurais MLP (Multilayer Perceptron) treinadas com algoritmos de retropropagação são as mais utilizadas. Porém, as MLPs possuem uma grande limitação, pois só conseguem o aprendizado do mapeamento entrada-saída com variáveis estáticas e desta forma, as MLPs só poderiam ser usadas para executar uma previsão não-linear em uma série temporal estacionária. Ocorre que em muitos problemas, o tempo pode conter informações importantes, sendo esse o caso da previsão de cargas.



As RNAs, por sua vez, apresentam duas estratégias de codificação da saída. Uma delas consiste em compor a camada de saída da rede com vários nós, obtendo os resultados de previsão de uma só vez. A segunda abordagem prevê composição da camada de saída com um único nó, utilizando esta saída de forma recorrente para alimentar as previsões seguintes, obtendo assim, todo o conjunto de previsão desejado (OLIVEIRA, 2004).

Além disso, os algoritmos genéticos também são utilizados de forma híbrida com as redes neurais na previsão de carga, sendo que sua função-objetivo, neste caso, envolve a otimização da estrutura das redes neurais, ajustes de pesos de conexões e seleção de variáveis de entrada para treinamento das redes (METAXIOTIS, et al., 2003). Exemplos de trabalhos desse gênero são encontrados em LING, et al. (2003), em WORAWIT & WANCHAI (2002) e em KATO, et al. (2002).

Comparações realizadas entre modelos híbridos utilizando algoritmo genético e redes neurais, e modelos utilizando somente redes neurais, comprovam a eficiência dos primeiros (WORAWIT & WANCHAI, 2002).

### **3.2 Variáveis de Entrada**

As variáveis utilizadas para a previsão de carga são de grande importância, entretanto, não existe um consenso entre quais sejam essas variáveis. Como entrada da RNA, as mais utilizadas são os históricos de carga, condições climáticas e comportamento periódico e sazonal da curva da carga (OLIVEIRA, 2004). Dentre as variáveis climáticas, a temperatura e umidade são as mais utilizadas.

Para uma maior precisão, simplicidade e eficiência da previsão é preciso usar o mínimo possível (e necessário) de variáveis de entrada. Para tanto, é essencial identificar as variáveis que exercem uma influência potencial no modelo a ser previsto. Porém, essa identificação é um dos trabalhos mais difíceis dentro do processo de previsão de carga.

Conforme já dito, a maioria dos trabalhos encontrados na literatura utiliza somente valores absolutos das variáveis, como, por exemplo, os trabalhos de Abdel-Aal (2004), Kato, et al. (2002), Beccali, et al. (2004), Kang, et al. (2004), Hsu & Chen (2003). Contudo, o uso das derivadas auxilia no processo de estacionaridade, tendo em vista que possibilita a identificação de uma tendência linear.

As variáveis candidatas utilizadas no modelo aqui apresentado são: carga, umidade, temperatura, velocidade do vento e radiação. Sendo o algoritmo genético responsável pela seleção das variáveis a serem utilizadas na rede neural.

## **4 PROJETO PCARGA**

O trabalho aqui descrito faz parte do projeto denominado PCarga, que tem como objetivo desenvolver um protótipo de o sistema previsor de carga ativa de curto prazo. Esse projeto é uma parceria entre a CELESC (Centrais Elétricas de Santa Catarina) e a UFSC (Universidade Federal de Santa Catarina).

O modelo de previsão utilizado foi proposto por OLIVEIRA (2004) e tem como objetivo a previsão de carga de curtíssimo e curto prazo, sendo a previsão de meia hora a frente em uma janela de uma semana. O modelo propõe uma estrutura inteligente e adaptativa, capaz de ajustar-se às características específicas de cada microrregião de consumo de energia elétrica e adaptar-se à dinâmica de cada uma dessas microrregiões, necessitando de um baixo nível de intervenção humana (OLIVEIRA, 2004).

Neste capítulo, será feita uma breve apresentação do funcionamento do modelo, sendo que maiores detalhes podem ser encontrados em OLIVEIRA (2004), bem como descrições dos experimentos realizados para validação do modelo.

### **4.1 Modelo Proposto**

O modelo proposto por OLIVEIRA (2004) apresenta uma arquitetura modular que permite uma fácil inclusão de novos pontos do sistema elétrico para previsão. Para ilustrar isso, a Figura 3 apresenta um esquema desse modelo, composto por: Base de Dados de Previsão, Construtor de Históricos, Previsor Especialista, Gerente de Exceções e Gerente de Tarefas Globais.

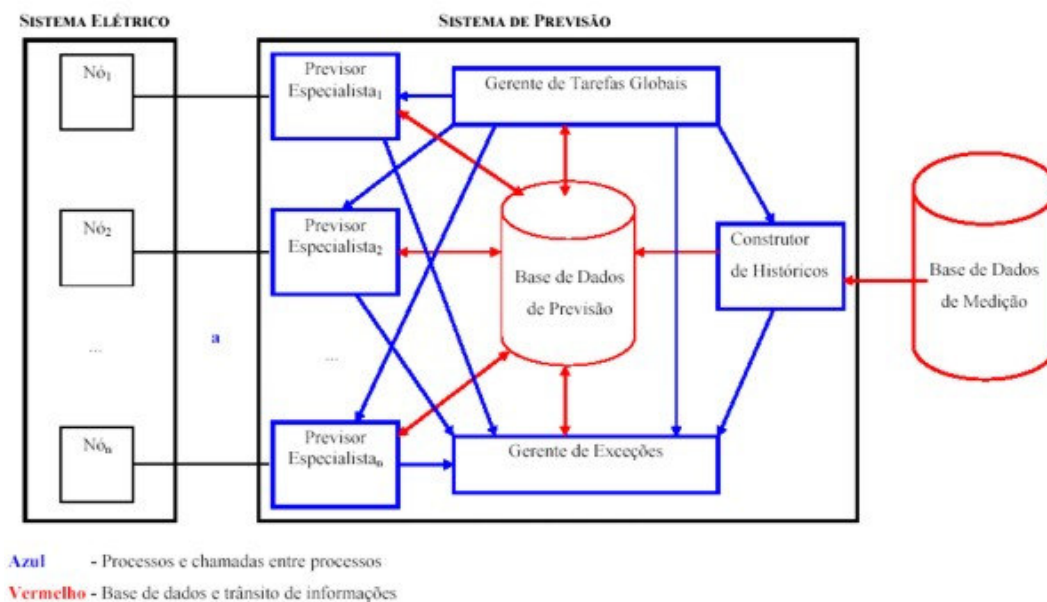
O sistema prevê ainda, uma conexão externa com uma Base de Dados e Medições, a qual é responsável pela alimentação do sistema com dados de medições de condições operacionais dos pontos do sistema elétrico e condições climáticas referentes a cada ponto de energia elétrica.

O módulo Construtor de Históricos é o responsável pela captura dos dados da Base de Dados de Medições e posterior formatação dessas informações para o armazenamento na Base de Dados de Previsão.

Essa Base armazena históricos de medições, parâmetros de ajuste do previsor especialista, histórico de previsões e outros processos internos ao sistema de previsão.

Paralelamente, o Gerenciador de Exceções faz o tratamento de falhas e anormalidades de funcionamento que venham a ocorrer durante o funcionamento do Sistema de Previsão. E o módulo Gerente de Tarefas Globais é responsável pelo controle e sincronismo das diversas atividades executadas pelos módulos especialistas.

Já os Previsores Especialistas são responsáveis pela previsão de carga dos vários pontos do sistema elétrico. Sendo que cada ponto terá um previsor designado, permitindo um ajuste preciso, conforme as necessidades do ponto de previsão. A seção seguinte apresenta o detalhamento do módulo Previsor Especialista.

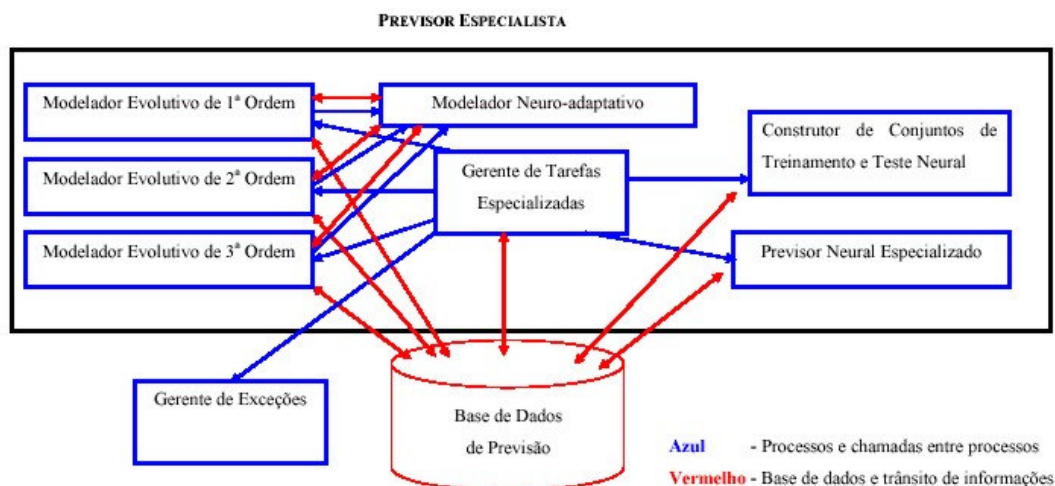


**Figura 3 – Esquema do Sistema de Previsão de Cargas**

Fonte: OLIVEIRA (2004)

## 4.2 Previsor Especialista

O Previsor Especialista possui duas finalidades: elaboração das previsões e adaptação e evolução do processo dos dispositivos de previsão. Ele permite que o sistema acompanhe a dinâmica do mercado de energia elétrica. Um esquema geral deste módulo pode ser observado na Figura 4.



**Figura 4 – Esquema do Previsor Especialista do Sistema de Previsão**

Fonte: OLIVEIRA (2004)

O Previsor Neural Especializado, contemplado na Figura 4, é em síntese, uma Rede Neural Artificial do tipo RBF, cujos detalhes podem ser encontrados em OLIVEIRA (2004), incluindo o motivo de sua escolha. No modelo apresentado, cada nó do sistema elétrico está relacionado com um Previsor Neural Especializado.

Quanto aos Modeladores Evolutivos, esses são algoritmos genéticos responsáveis pela adaptação do sistema, possibilitando que o modelo acompanhe as características relevantes da dinâmica do mercado de energia elétrica, sendo que o de 1ª Ordem é responsável pelas adaptações iniciais do Previsor Neural Especializado e as adaptações evolutivas periódicas de médio prazo, de semanas a meses a frente. Já o de 2ª Ordem é responsável pelo refinamento da adaptação inicial do Previsor Neural Especializado e por produzir adaptações evolutivas periódicas de curto prazo, de horas a dias a frente. E o modelador de 3ª Ordem tem por finalidade pré-formatar as informações necessárias ao

módulo do Modelador Neuro-adaptativo e garantir as adaptações evolutivas periódicas de curtíssimo prazo, ou seja, de minutos a frente.

Esse Modelador Neuro-adaptativo, a partir das informações contidas nos conjuntos de treinamento, testes e especificações dos Modeladores Evolutivos, ajusta o Previsor Neural Especializado, adaptando-o ao nó associado à previsão.

Nesse contexto, o Construtor de Conjuntos de Treinamento e Teste Neural é responsável pela criação dos conjuntos, treinamento e testes a serem utilizados pelo módulo Modelador Neuro-adaptativo.

Em contrapartida, o módulo Gerente de Tarefas Especializadas tem como função o controle e sincronização das diversas atividades executadas pelos módulos do Previsor Especialista.

Observe-se que as hipóteses desta dissertação envolvem o módulo Modelador Evolutivo de 1ª Ordem, o qual será apresentado mais detalhadamente.

#### **4.2.1 Previsor Neural Especializado**

Conforme já citado, o Previsor Neural Especializado é uma Rede Neural Artificial do tipo RBF, detalhes referente a sua arquitetura podem ser encontrados em Oliveira (2004).

As variáveis de entrada da primeira camada da rede são selecionadas pelo Modelador Evolutivo de 1ª Ordem. Já a segunda camada recebe parâmetros de ajustes identificados pelos Modeladores Evolutivos e também obtidos através do treinamento da Rede.

A terceira camada, também conhecida como camada de saída, é composta de um nó, o qual representa o valor objetivo da previsão, ou seja, o valor futuro da carga meia hora a frente, cujos valores vão sendo obtidos através do uso recorrente da rede, obtendo-se assim, a previsão a cada meia hora em uma janela de uma semana a frente.

Para a avaliação do erro da Rede, foi adotado o índice RMSE - Root Mean Squared Error, conforme demonstra-se na fórmula (1).

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (T_{(ik)} - T_k)^2} \quad (1)$$

Onde:

$T_{ik}$  valor previsto da carga para o k-ésimo elemento da série

$T_k$  valor real da carga para o k-ésimo elemento da série

$n$  número de elementos da série

Detalhes sobre a escolha deste índice podem ser encontrados em OLIVEIRA (2004).

#### **4.2.2 Modelador Evolutivo de 1ª Ordem**

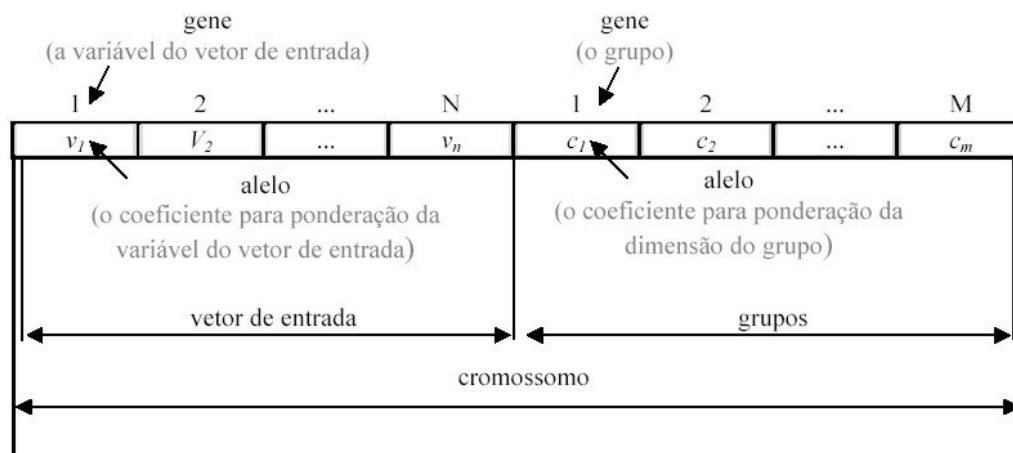
A seleção das variáveis de entrada relevantes para a Rede Neural Artificial (RNA) é feita pelo Modelador Evolutivo de 1ª Ordem. Esse modelador está fundamentado na técnica de computação evolucionária conhecida como Algoritmo Genético, apresentado na seção 2.2.

Além de escolher de forma ótima as variáveis de entrada para a rede neural, também tem como função a escolha dos coeficientes de ponderação dos valores de cada uma das variáveis escolhidas, do número de agrupamentos da camada intermediária da rede e dos coeficientes para ponderação da dimensão de cada um dos agrupamentos.

Esse algoritmo genético, caracterizado como um problema de otimização, foi modelado como um cromossomo, onde cada gene representa um parâmetro da rede a ser otimizado e o alelo (conteúdo do gene) constitui-se no valor para este parâmetro.

O cromossomo, conforme apresentado na Figura 5, pode ser dividido em duas partes, sendo a primeira delas a representação das variáveis candidatas que compõem o vetor de entrada da RNA cujos valores dos alelos ( $v_n$ ) variam no intervalo  $[0,1]$ ,  $v_n \in \mathfrak{R}$ , onde o valor “0” significa a inexistência desta variável no vetor de entrada e  $n$  representa o número de variáveis candidatas ao vetor de entrada da rede. A segunda parte representa os grupos que compõem a camada intermediária da RNA e nesse caso, os valores dos alelos ( $c_m$ ) variam no intervalo  $[0, 3]$ ,  $c_m \in \mathfrak{R}$ , onde o valor “0” significa

a inexistência deste grupo na camada intermediária e  $m$  é o número máximo, fixado em 100, de grupos permitidos na camada intermediária da rede neural.



**Figura 5 – Representação Genética do Modelador Evolutivo de 1ª Ordem**

Fonte: OLIVEIRA (2004)

Diante disso, as variáveis candidatas a compor o vetor de entrada da RNA são selecionadas a partir: (a) do conjunto de variáveis disponíveis, (b) da revisão bibliográfica, (c) do conhecimento extraído de técnicos da Celesc acerca do comportamento do sistema elétrico e (d) do conhecimento acumulado em trabalhos correlacionados (OLIVEIRA, 2004). Um conjunto de variáveis candidatas foi apresentado por OLIVEIRA (2004), sendo que este número pode aumentar de acordo com a necessidade de novas variáveis ou diminuir conforme a comprovação de ineficiência de algumas variáveis.

Para a implementação do Algoritmo Genético foi utilizada como base a biblioteca de funções GAOT de HOUCK & JOINES (1996). OLIVEIRA (2004) realizou algumas adaptações e extensões das funções do código, conforme necessidades do projeto.

Onde, as funções de *crossover* utilizadas no modelo foram *simpleXover*, *heuristicXover*, *arithXover* e *PCargaXover*, sendo a última implementada especificamente para o projeto. Essas funções geram dois novos descendentes a partir de dois indivíduos selecionados, sendo que o diferencial das funções está no ponto de corte e forma de cruzamento dos indivíduos.



Já as funções de mutações utilizadas foram *boundaryMutation*, *multiNonUnifMutation*, *nonUnifMutation*, *unifMutation*, *PCargaUnifMutation*, *PCargaMutation* e *PCargaCiclicMutation*, sendo as três últimas desenvolvidas especialmente para o projeto. Foram utilizadas combinações das funções de mutação com uma probabilidade variando de 8% a 14%, sendo que a probabilidade ótima, localizada através dos experimentos, foi de 8%.

A função de mutação *PCargaMutation* utilizada no projeto é a função proposta neste trabalho, a qual é apresentada no capítulo 5.

Uma descrição mais detalhada das funções de *crossover* e mutação podem ser encontradas em HOUCK & JOINES (1996) e OLIVEIRA (2004).

### 4.3 O Objeto de Estudo do Projeto PCarga

O mercado de energia elétrica do Estado de Santa Catarina<sup>6</sup> serviu como objeto de estudo para o projeto devido sua característica heterogênea de consumo.

Para a realização do estudo foram utilizados seis pontos do sistema de potência da CELESC em três estações climáticas do ano, sendo elas: verão, outono e inverno. Os pontos foram escolhidos levando-se em consideração, principalmente, o diferencial de comportamento entre eles. Os períodos abordados compreenderam 4 semanas, sendo eles: verão, no período de 13/01/2003 a 09/02/2003; outono, no período de 05/05/2003 a 01/06/2003; e inverno, no período de 14/07/2003 a 10/08/2003.

Os pontos selecionados foram: subestação Trindade (TDE), subestação Ilha Norte (INE), subestação Ilha Centro (ICO), subestação Itajaí Salseiros (ISS), transformadores da Sadia abastecidos pela subestação Concórdia (SAD) e subestação Seara (SRA).

A descrição detalhada do objeto de estudo, bem como os pontos e períodos selecionados, podem ser encontrados em OLIVEIRA (2004).

---

<sup>6</sup> Em especial o mercado das Centrais Elétricas de Santa Catarina - CELESC

#### **4.4 Experimentação do Projeto PCarga**

O processo de experimentação foi dividido em duas etapas. A primeira foi realizada para auxiliar na construção e ajustes de parâmetros do projeto. Nela foi utilizada a massa de dados de apenas um ponto do sistema elétrico. Já a segunda etapa iniciou-se após ajustes identificados através da etapa I e compreendeu todos os pontos e períodos definidos como objeto de estudo.

Para avaliação dos Modeladores Evolutivos, utilizou-se como índice a minimização do RMSE. Por tratar-se de experimentos que envolvem técnicas probabilísticas, os experimentos foram repetidos com o objetivo de confirmação dos resultados.

Maiores detalhes de configurações e ajustes dos algoritmos podem ser obtidos em OLIVEIRA (2004).

## 5 HIPÓTESE I - FUNÇÃO DE MUTAÇÃO EM GRUPO

O objetivo da função de mutação no algoritmo genético é a quebra da estacionaridade no algoritmo. A vantagem de sua utilização é a que a mutação pode levar a resultados possivelmente inesperados.

Essa hipótese considera a possibilidade de criar-se uma função de mutação para manipular grupos de variáveis (e.g. todos os valores de umidade). Isso permitiria que o algoritmo genético, ao invés de trabalhar com valores pontuais, identificasse conjuntos de variáveis relevantes (ou irrelevantes) para o processo de previsão, fazendo com que o algoritmo convergisse mais rapidamente para uma solução.

É importante lembrar que no caso da mutação não gerar bons resultados (*fitness*), a probabilidade de reprodução deste indivíduo será significativamente pequena, porém, uma boa avaliação do indivíduo significa a localização de uma possível melhoria na direção da solução do problema.

A hipótese I fez parte da Etapa 1 do projeto PCarga, que teve como finalidade realizar ajustes no sistema predictor. Neste capítulo é feita uma descrição dos procedimentos realizados para comprovação desta hipótese.

### 5.1 Delineamento do Experimento

Para a realização dos experimentos, foi escolhido o grupo do PCarga que apresentou as menores taxas de erros durante a Etapa I do projeto, sendo utilizado como índice de comparação, o RMSE (Root Mean Squared Error), que nos experimentos apresentou uma taxa de erro média de 0,84MW<sup>7</sup>.

Para o processo de validação, os experimentos aqui apresentados possuem as mesmas configurações definidas no grupo de experimentos do PCarga. Sendo ela uma

---

<sup>7</sup> Valores referenciais encontram-se no anexo 9.2

massa de dados sem normalização, do período de 10/06/2002 a 07/07/2002, do ponto da Trindade. O vetor de entrada possuía valores. A população estava constituída de 50 indivíduos, sendo realizadas 3000 gerações e porcentagem de mutação de 8%.

Para ajustes do experimento aqui relatado, foi feita uma redução do número de gerações para 2000, já que houve convergência muito antes deste valor e a adição de uma etapa de mutação de grupo de 2%, sendo mantida a taxa de mutação individual original em 8%.

## 5.2 Descrição dos Grupos

Para efetivação da pesquisa fez-se uma análise para a identificação de grupos de variáveis relevantes no conjunto total de dessas, onde foram identificados três grandes grupos, quais sejam:

- a) **Conjunto 1 - Época do ano:** compõe-se das variáveis agora, semana e ano, representadas por 1, 2 e 3 respectivamente.
- b) **Conjunto 2 - Tipo de variável:** variáveis de temperatura e umidade; valores 1 e 2 respectivamente.
- c) **Conjunto 3 - Deslocamento da variável:** valores absolutos do momento zero (atual), meia hora antes, uma hora antes e suas diferenças de primeira e segunda ordem (derivada atual, derivada meia horas antes, segunda derivada atual e segunda derivada meia hora antes). Sendo essas variáveis representadas por valores de 1 a 7 respectivamente.

Para a identificação dessas variáveis no algoritmo genético, foi criada uma matriz de três colunas, onde cada coluna representa um conjunto acima e cada linha representa a variável a ser identificada. Nesse caso, a atribuição de valor zero para essa variável representa que a mesma não pertence a nenhum tipo indicado no conjunto.

Por exemplo, a variável nomeada como “AGORA\_DerivadaUmidadeAtual” tem sua matriz com valores: 1 2 4, indicando que a mesma pertence ao conjunto 1 (tipo

agora), conjunto 2 (tipo umidade) e conjunto 3 (tipo DerivadaAtual). Com a finalidade de explicitar melhor esse ponto, o Anexo 9.1 apresenta a classificação completa das variáveis utilizadas no experimento.

Observe-se que as variáveis que envolvem valores de carga não foram classificadas dentro dos conjuntos 1 e 2, pois foram consideradas variáveis importantes para o processo de previsão. Isso por representarem a variável objetivo no modelo de previsão, de forma que a desativação dessa variável em um desses conjuntos poderia prejudicar tal processo.

Para executá-lo, portanto, a função de mutação recebe três valores como parâmetro, sendo o primeiro, a porcentagem da mutação; o segundo valor, que pode variar de 0 a 3, representa qual o conjunto de variável irá sofrer a mutação, onde o valor 0 indica uma seleção aleatória do conjunto. E o terceiro parâmetro, também variando de 0 a 3, representa o tipo de mutação que será aplicada, onde o valor 0 indica a seleção aleatória do tipo de mutação e os valores 1, 2 e 3 representam respectivamente:

- a) Desativação do conjunto indicado, ou seja, a mudança dos genes para o valor 0;
- b) Ativação do conjunto indicado, ou seja, a mudança dos genes para o valor 1;
- c) Inversão dos valores dos genes, onde os genes com valor 1 mudam para 0 e os valores 0 para 1.

Foram então realizados quatro experimentos com um total de 10 repetições. Devido ao limite de tempo para realização dos experimentos, decidiu-se por deixar aleatória a escolha do tipo de operação, fazendo-se variações apenas na seleção dos conjuntos. Sendo os experimentos dessa etapa nomeados como série A onde:

- a) ExpA1 – deixou-se a seleção aleatória dos conjuntos (valor 0), ou seja, a mutação é realizada aleatoriamente nos conjuntos 1, 2 e 3;
- b) ExpA2 - mutação apenas nas variáveis dos conjuntos 2 e 3;
- c) ExpA3 - mutação nas variáveis do conjunto 2;
- d) ExpA4 - mutação nas variáveis do conjunto 3.

### 5.3 Resultados

O valor médio da taxa de erro da previsão RMSE dos experimentos do PCarga, que não faziam uso da função de mutação de grupo, para uma amostra de tamanho  $n=10$  foi de  $\bar{X}=0,84\text{MW}$ , sendo o desvio padrão de  $S = 0,0485\text{MW}$ .

Através da realização do teste de hipóteses com amostras de tamanhos iguais<sup>8</sup> e nível de significância de 5%, identificou-se que experimentos com taxas de erro médio (RMSE) abaixo de 0,81MW podem ser considerados como uma melhora de desempenho do algoritmo de mutação. O valor de  $\bar{X}_c$  de 0,81MW foi obtido através dos cálculos demonstrados no Quadro 2.

Tamanho da Amostra: $n = 10$ (t = 9 graus de liberdade)
Nível de Significância: $\alpha = 0,05$   $t = 2,262$
$\bar{X} = 0,84$   $S=0,049$
<b>Cálculo do Valor Crítico Inferior:</b>
$\bar{X}_c = \bar{X} + t * \left( \frac{S}{\sqrt{n}} \right) \rightarrow 0,84 - 2,262 * \left( \frac{0,049}{\sqrt{10}} \right) \rightarrow 0,81\text{MW}$

**Quadro 2 – Cálculo do Valor Crítico**

Fonte: Adaptação de MORETTIN & BUSSAB (2002)

Os valores médios obtidos nos experimentos que utilizam a função de mutação em grupo podem ser vistos na Tabela 1.

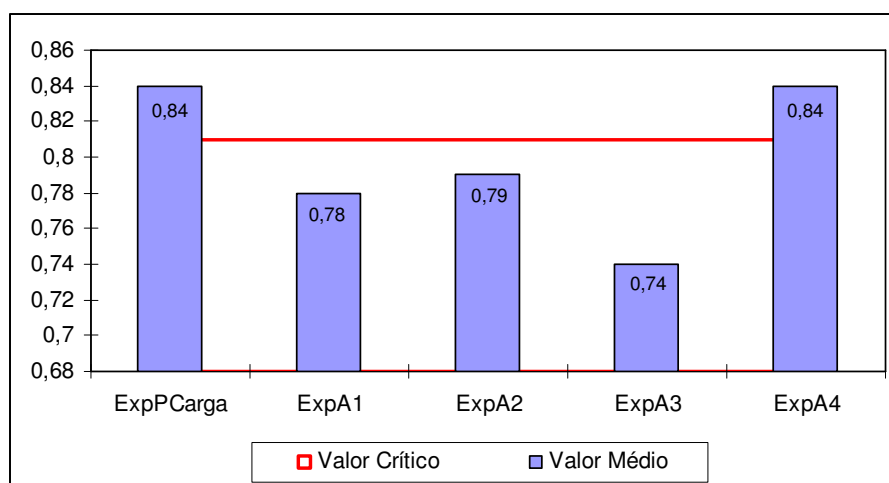
**Tabela 1 – Comparação das Médias (RMSE) dos experimentos**

Experimento	RMSE – Treino (MW)		
	$\mu$	$\sigma$	$\sigma^2$
ExpPCarga	0,84	0,0485	0,0024
ExpA1	0,78	0,0394	0,0016
ExpA2	0,79	0,0453	0,0021
ExpA3	0,74	0,0419	0,0018
ExpA4	0,84	0,0289	0,0008

De outro modo, na Figura 6 pode-se notar as taxas de erro médio dos experimentos comparadas ao valor crítico obtido no teste de hipóteses.

<sup>8</sup> Teste de Hipóteses: verifica a validade de uma hipótese através da comparação de dois experimentos.

Através desses resultados, pode-se perceber que o ExpA3 obteve os melhores resultados comparados aos experimentos do PCarga, estando abaixo do valor crítico. O experimento A3 fixa a mutação no conjunto 2, o qual representa os tipos de variáveis, neste caso, temperatura e umidade. Isso demonstra que os tipos de variáveis têm uma forte influência no processo de previsão de carga, sendo que a mutação possibilitou a ativação e/ou desativação de todas as variáveis deste conjunto, permitindo a inclusão e/ou eliminação dessas variáveis, influenciando assim no processo final de previsão.



**Figura 6 – Comparação das médias como referência ao Valor Crítico**

Já o ExpA4, que representa o deslocamento das variáveis trabalhando com o conjunto 3, não apontou melhorias comparado aos experimentos do PCarga, estando sua taxa de erro médio acima do valor crítico. O que demonstra que o trabalho em grupo dessas variáveis não interfere no processo de previsão. Este é um ponto instigante, que exerce influência na próxima etapa, a qual irá testar a hipótese 2, que sugere a existência de grupos de variáveis de deslocamento relevantes e irrelevantes para o processo de previsão.

Tanto o ExpA1 quanto o ExpA2 tiveram um bom desempenho comparado ao experimento do PCarga, estando sua taxa de erro médio abaixo do valor crítico, porém não obtiveram o mesmo desempenho do ExpA3. O ExpA1 e ExpA2 trabalham com a mutação aleatória dos conjuntos 1, 2 e 3 e os conjunto 2 e 3 respectivamente. Os resultados satisfatórios desses experimentos se deram devido à inclusão do conjunto 2, que ocasionou uma certa influência nos resultados da previsão.


Quanto à velocidade de convergência, pode-se ver as comparações na Tabela 2, a qual demonstra o número médio de gerações até o algoritmo genético obter o melhor indivíduo.

**Tabela 2 – Comparação do tempo de convergência em número de gerações**

Experimento	Convergência (gerações) Todos Experimentos		Convergência (gerações) Experimento com Melhor RMSE Treino	
	$\mu$ (MW)	$\sigma$	RMSE (MW)	Convergência
<b>ExpPCarga</b>	1324,7	954,54	0,72	1699
<b>ExpA1</b>	818	594,61	0,70	296
<b>ExpA2</b>	546,42	467,12	0,71	213
<b>ExpA3</b>	1058,57	365,48	0,69	944
<b>ExpA4</b>	1060	379,91	0,79	464

Ao se comparar o tempo de convergência médio de todos os experimentos, percebe-se que a maior média foi dos experimentos do PCarga, com 1324,7 gerações e um desvio padrão de 954,54 gerações, um valor elevado quando comparado aos demais desvios padrão.

Fazendo a comparação do melhor resultado de cada experimento, referente à taxa de erro RMSE-Treino, pode-se observar que o melhor experimento obtido no ExpPCarga levou 1699 gerações para encontrar o melhor indivíduo, sendo que os demais experimentos localizaram os melhores indivíduos sempre antes de chegar em 1000 gerações.



**Figura 7 – Valores Médios e de Dispersão do Tempo de Convergência dos Experimentos**

Pode-se notar, na Figura 7, o tempo médio e a dispersão do tempo de convergência dos experimentos, comparados ao experimento do PCarga. Além do valor



médio dos experimentos estarem abaixo do PCarga, pode-se notar que a dispersão dos valores de convergência do PCarga é superior, se comparado ao demais experimentos.

Isso demonstra que a mutação em grupo trouxe resultados positivos quanto ao tempo de convergência levando-se em consideração o número de gerações. Ou seja, função fez com que o algoritmo convergisse mais rapidamente, de forma a encontrar melhores indivíduos ou soluções.

## **5.4 Conclusões**

Pôde-se perceber que a função de mutação em grupo apresentou os resultados esperados, ou seja, possibilitou uma convergência mais rápida, considerando-se o número de gerações, além de melhorar a qualidade da previsão e reduzir sua taxa de erro comparativamente aos experimentos realizados sem o uso desta função.

Com os resultados preliminares das experimentações, pode-se visualizar esta melhoria, sendo que a função de mutação em grupo já foi agregada como parte constituinte do sistema previsor do projeto PCarga.

## 6 HIPÓTESE II – UTILIZAÇÃO DE SUBGRUPOS DE VARIÁVEIS CANDIDATAS

O modelo de previsão proposto por OLIVEIRA (2004) possui um Previsor Especialista responsável pela previsão de carga, o qual utiliza técnicas de redes neurais artificiais. Neste módulo, as redes neurais são ajustadas através de algoritmos genéticos, sendo este último o responsável pela otimização do vetor das variáveis de entrada relevantes para rede neural.

O algoritmo genético é representado por uma cadeia de *bits* composta por genes que representam o conjunto de variáveis candidatas para a entrada da rede neural. Esse conjunto poderá sofrer alterações com o tempo, de forma a agregar novas variáveis que poderão ser consideradas relevantes ou eliminar as ineficientes. Dentre as variáveis candidatas, pode-se citar: carga, umidade, temperatura, velocidade do vento e radiação.

Para cada uma dessas variáveis é possível uma variação referente ao seu histórico, podendo-se trabalhar com dados do dia a ser previsto, de uma semana anterior e um ano antes, as quais são aqui denominadas “agora”, “semana” e “ano” respectivamente.

No modelo proposto, cada variável pode possuir um deslocamento referente ao tempo e suas diferenciações, sendo um total de nove variações, onde os valores absolutos da série variam entre o momento zero, 30 minutos antes, 60 minutos antes, e 90 minutos antes, e a diferença desses valores geram a derivada de primeira ordem e, conseqüentemente, a derivada de segunda ordem. O valor zero tem como referência o instante que está sendo previsto, sendo que o processo de previsão é repetido levando-se em consideração cada instante no intervalo de 30 minutos com a janela de uma semana.

Pode-se perceber que o número de variáveis candidatas é bastante extenso, pois para cada variável, existe a possibilidade de 27 valores (as nove variações contempladas nos três períodos possíveis – agora, semana, ano). Logo, com o passar do tempo, a inclusão de uma variável no algoritmo genético acarretaria na inclusão de 27 novos valores (genes), o que tornaria longo o tempo total de evolução do algoritmo genético.

Como hipótese, acredita-se que a redução do número de variáveis candidatas nesse algoritmo pode melhorar a precisão e eficiência do processo de previsão. Uma possibilidade de corte está nas variáveis de deslocamento e suas diferenças. É preciso lembrar que utilização de todos esses valores acarreta ainda, uma redundância de valores, pois alguns dos valores são derivados dos valores absolutos. Assim, verifica-se a hipótese de que exista uma combinação dessas variáveis de deslocamento, que apresente os valores relevantes e diminua desse modo a redundância de valores.

Neste capítulo será feita a descrição dos experimentos realizados para validar esta hipótese.

## **6.1 Delineamento do Experimento**

Os experimentos para validação da hipótese supra citada fazem parte da Etapa II do projeto PCarga, onde, após feitos os ajustes identificados na Etapa I, foram realizados experimentos envolvendo seis pontos com diferentes características de consumo, dentre os quais: subestação Trindade (TDE), subestação Ilha Norte (INE), subestação Ilha Centro (ICO), subestação Itajaí Salseiros (ISS), transformadores da Sadia abastecidos pela subestação Concórdia (SAD) e subestação Seara (SRA), sendo que para cada um dos seis pontos do sistema de potência foram utilizados dados de três estações climáticas: verão, outono e inverno.

Sendo que os experimentos deste trabalho foram realizados em apenas dois pontos: ICO – Ilha Centro e INE – Ilha Norte, porém fazendo uso das três estações climáticas.

No intuito de validar os experimentos para comprovar a hipótese deste trabalho foram utilizadas as mesmas configurações e ajustes dos experimentos do PCarga. Onde envolveram todas as variáveis disponíveis para os pontos ICO e INE, sendo o objetivo deste trabalho a minimização do índice RMSE (Root Mean Squared Error).

## 6.2 Descrição dos Experimentos

Para comprovar esta hipótese, seria interessante realizar experimentos englobando todas as combinações possíveis das variáveis de deslocamento, porém isso não seria viável devido à existência de uma imensa variedade de combinações. A Figura 8 apresenta um mapa com todas as variáveis absolutas e suas diferenciações, sendo todo esse conjunto utilizado nos experimentos do PCarga.

Seria possível trabalhar com combinações de uma até nove variáveis, resultando assim em um valor astronômico de combinações. Este fato ainda se agrava pela necessidade de utilizar um parque computacional em rede durante várias horas para avaliar um único experimento. Por este motivo é que se optou por trabalhar com três combinações representativas: todos os valores absolutos (técnica predominante na literatura), todas as derivadas de primeira ordem, e todas as derivadas de segunda ordem.



**Figura 8 – Deslocamentos das variáveis**

Para a escolha do grupo de experimentos, foram levados em consideração os resultados obtidos nos experimentos realizados com a função de mutação em grupo apresentados no capítulo 5, onde não foram obtidos resultados satisfatórios quando os experimentos envolviam conjuntos de variáveis de deslocamento. O que indica que não deve ser relevante para o vetor de entrada desativar ou ativar todas as variáveis que envolvem tais valores. Por exemplo, desativar todas as variáveis relacionadas a Derivada\_Atual.

Assim, foram escolhidas três variações de experimentos, inicialmente com um total de três repetições, denominados como série B:

- a) ExpB1: realizou-se um trabalho envolvendo apenas as variáveis de deslocamento com valores absolutos (atual, meia hora antes, uma hora antes e uma hora e meia antes).
- b) ExpB2: envolveu apenas as variáveis de deslocamento com diferenças de primeira ordem (derivada atual, derivada meia hora antes e derivada uma hora antes).
- c) ExpB3: envolveu as variáveis de deslocamento com diferenças de segunda ordem (segunda derivada atual e segunda derivada meia hora antes).

### 6.3 Resultados

A Tabela 3 apresenta as taxas de erro médias (RMSE) dos três experimentos realizados comparadas ao experimento do PCarga, sendo que o valor crítico foi obtido através do teste de hipóteses utilizando t com 2 graus de liberdade e nível de significância de 5%, onde o valor de  $t = 4,303$ . O Valor Crítico representa o valor de limite superior da média, que baseados nos experimentos o PCarga, pode ser considerado uma melhora nos experimentos caso não ultrapasse este limite, ou seja, os experimentos que apresentarem uma média acima desses valores críticos não são considerados como melhoras em relação à versão original do projeto PCarga.

Tabela 3 – Comparação das Médias (RMSE-Treino) dos experimentos

Ponto	ExpPCarga		Valor Crítico Teste de Hipótese	ExpB1		ExpB2		ExpB3	
	$\mu$	$\sigma$		$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$
ICO – Inv	0,1287	0,0019	<b>0,1334</b>	0,1734	0,0184	0,5475	0,0185	1,0815	0,0167
ICO – Out	0,1588	0,0014	<b>0,1623</b>	0,2483	0,0101	0,8815	0,0448	1,8171	0,0714
ICO – Ver	0,1975	0,0012	<b>0,2005</b>	0,3378	0,0297	1,7932	0,0000	3,0546	0,0280
INE – Inv	0,2597	0,0066	<b>0,2761</b>	0,2893	0,0055	0,7776	0,0000	**	**
INE – Out	0,2251	0,0039	<b>0,2348</b>	0,2976	0,0168	0,9723	0,1054	**	**
INE – Ver	0,4116	0,0059	<b>0,4263</b>	0,5679	0,0335	1,4369	0,0245	**	**

O objetivo dos experimentos, conforme a hipótese original, era a minimização das taxas de erro médio, porém, foi observado que essa melhoria não foi obtida. Considerando-se que todos os experimentos apresentaram uma média de erro bastante

acima do ponto considerado crítico, com um grau crescente da média de erro conforme os valores dos experimentos se distanciam dos valores absolutos.

Pode-se observar, através da Figura 9, uma evolução da diferença das taxas de erro média (RMSE) dos experimentos, comparadas ao valor crítico.

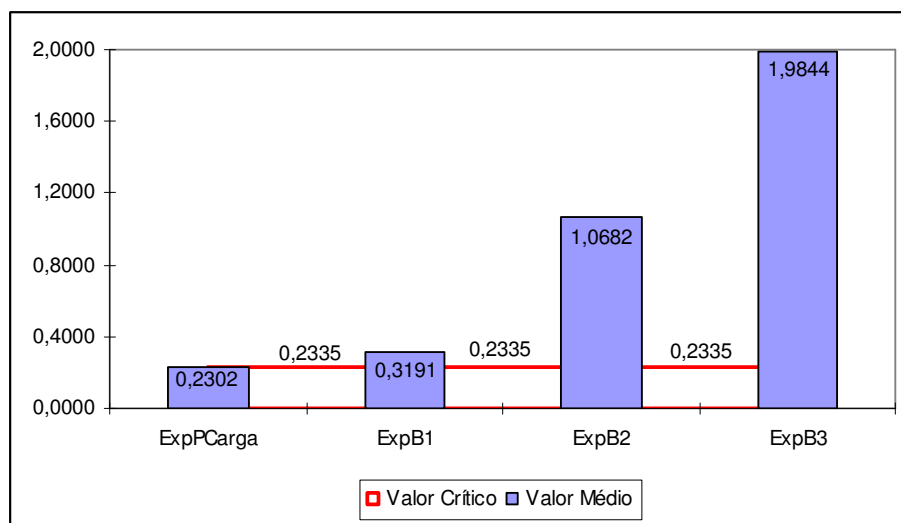


Figura 9 – Resumo das taxas de erro médio de erro (RMSE) dos experimentos

## 6.4 Conclusões

Experimentos realizados no projeto PCarga envolveram a troca de vetores de entrada encontrados como soluções para cada ponto, sendo que as soluções obtiveram um bom desempenho no seu ponto de origem. Todavia, ao utilizar a solução encontrada, em outro ponto qualquer, os resultados não foram satisfatórios (OLIVEIRA, 2004). Portanto, as características singulares dos pontos fazem com que as necessidades sejam diferentes, dificultando a existência de um vetor de variáveis de entrada padrão para todo e qualquer ponto.

Assim, a hipótese da existência de que o uso de um único tipo de variáveis de deslocamento melhora a eficiência da rede mantendo a sua precisão pode ser descartada, pois a precisão piora significativamente.

Os resultados apresentados neste capítulo servem como um alerta, visto que a maioria dos trabalhos encontrados na literatura utiliza somente valores absolutos como entrada para as redes neurais. Observou-se nesta pesquisa que os experimentos que utilizam apenas os valores absolutos não obtiveram o mesmo sucesso dos experimentos que permitem a utilização combinada com valores de diferenciação.

É importante ressaltar que para Silva et al. (2001), os valores de diferenciação, para algumas variáveis, podem ser tão importantes quanto os valores absolutos, uma vez que esse processo de diferenciação auxilia na identificação da estacionaridade, possibilitando a visualização de uma tendência linear.

Diante disso, os experimentos indicam que para se ter uma melhor qualidade nas previsões das redes, para este tipo de aplicação, é importante trabalhar com combinações de valores absolutos e derivados.

## 7 CONSIDERAÇÕES FINAIS

Este trabalho atingiu seus objetivos ao apresentar uma contribuição significativa para o projeto PCarga, desenvolvido pela Universidade Federal de Santa Catarina em parceria com a CELESC e que prevê a criação de um sistema previsor de carga ativa de curto prazo, proposto por Oliveira (2004).

Resumidamente, os objetivos desta pesquisa envolveram hipóteses de trabalho que possibilitassem uma melhoria de desempenho do modelo e uma das possibilidades de melhoria estava no processo de convergência do algoritmo genético utilizado no modelo como otimizador das variáveis de entrada para a rede neural, responsável pela previsão.

Com o intuito de melhorar o desempenho do algoritmo genético, foram então verificadas duas possíveis hipóteses de trabalho, na tentativa de reduzir o seu tempo de convergência.

A primeira hipótese consistiu na idéia de criar uma função de mutação simultânea em grupos específicos de variáveis, possibilitando que o algoritmo tenha uma convergência mais rápida comparada ao trabalho de mutação individual.

Para comprovação da hipótese I, foram realizados experimentos simultâneos à Etapa I do projeto PCarga, que teve como finalidade a realização de ajustes no sistema previsor.

Para facilitar o processo de validação, foi escolhido o grupo de experimentos do PCarga que apresentou as menores taxas de erros durante a Etapa I do projeto, possibilitando-se a comparação dos experimentos com e sem a utilização da função de mutação em grupo.

Comparados aos experimentos do PCarga, que obtiveram uma taxa de erro média (RMSE) de 0,84MW, os experimentos que utilizaram a função de mutação de grupo obtiveram uma taxa de erro média de 0,74MW, 0,78MW e 0,79MW. Através do teste



de hipóteses com um nível de significância de 5%, pôde-se comprovar que tais resultados apontam para uma melhoria significativa do erro médio.

O experimento que trabalhou com a função de mutação de grupo apenas nas variáveis de deslocamento manteve a média de erro de 0,84MW, indicando que este tipo de mutação não apresenta resultados significativamente melhores do que a mutação individual. Esse resultado, relaciona-se com a comprovação da negação da hipótese II, ou seja, o fato de ligar e desligar grupos inteiros de variáveis de deslocamento não melhora a qualidade das previsões. A hipótese II, por outro lado, confirmou isso e apresentou evidências fortes de que a previsão com apenas um tipo de variável de deslocamento não gera resultados melhores do que a previsão com combinações heterogêneas deste tipo de variável.

Em relação à taxa de convergência, os quatro experimentos relacionados à hipótese I apresentaram uma taxa média inferior aos experimentos do PCarga. Sendo que, a maioria dos experimentos chegou a uma convergência antes de 1000 gerações, enquanto que os experimentos do PCarga atingiam o erro mínimo em cerca de 1300 gerações em média. Além disso, observou-se que os resultados obtidos com a função de mutação de grupo foram mais confiáveis, pois o desvio padrão do erro médio obtido em cada experimento foi muito menor do que o desvio padrão dos experimentos sem a função de mutação. Assim, conclui-se que além de obter resultados melhores e mais rápidos na média, a função de mutação em grupo produz resultados menos discrepantes em relação à qualidade da previsão.

A hipótese I foi validada, portanto, apresentando os resultados esperados, ou seja, possibilitou uma convergência mais rápida, considerando-se o número de gerações, e melhorou a qualidade da previsão, comparada aos experimentos sem a utilização da função de mutação em grupo.

No que tange à segunda hipótese, essa trabalhou com a idéia de redução do tamanho do cromossomo do algoritmo genético, através da eliminação de variáveis de deslocamento redundantes (valores absolutos e derivados).

Foram realizadas três variações de experimentos, sendo que o primeiro grupo utilizou apenas os valores absolutos das variáveis, o segundo grupo, valores derivados de primeira ordem, e o terceiro grupo valores derivados de segunda ordem.

Todos os experimentos apresentaram o RMSE acima do valor crítico apresentado pelo teste de hipóteses. Em todos os casos, foi possível comprovar a hipótese contrária, o que significa que a combinação de valores absolutos e derivados, ao invés da utilização de apenas um tipo destes valores, é fundamental para a boa qualidade das previsões da rede neural. Tal resultado tem um significado muito importante, uma vez que a maioria dos trabalhos consultados na literatura internacional trabalha sempre com uma combinação de valores pré-definida; apenas com valores absolutos ou com uma combinação pré-definida de valores absolutos e derivadas.

O que este trabalho aponta, então, é que em algumas situações e para algumas variáveis climáticas ou de carga, será mais relevante para a qualidade da previsão o uso de valores absolutos, enquanto que para outras variáveis será mais interessante usar derivadas, ou mesmo combinações destas. Assim, pode-se confirmar a suposição inicial do projeto PCarga de que a qualidade da previsão pode ser melhorada quando se permite ao algoritmo genético escolher o conjunto de variáveis de entrada, ao invés de defini-las com antecedência.

Como trabalhos futuros, sugere-se testar outras combinações de variáveis de deslocamento em contraposição aos três conjuntos já testados. Além disso, sugere-se um estudo de mineração de dados para tentar-se descobrir se existem regularidades entre as condições climáticas, o tipo de demanda (comercial, residencial, etc.) e o tipo de variável relevante ao processo de previsão.

## 8 REFERÊNCIAS

- [1] ABDEL-AAL, 2004 - Abdel-Aal, R.E. *Short-Term Hourly Load Forecasting Using Abductive Networks*. Power Systems, IEEE Transactions on , Volume: 19 , Issue: 1 , Feb. 2004. Pages: 164 – 173.
- [2] ABU-EL-MAGD, et al., 2003 - Abu-El-Magd, M.A.; Findlay. *A new approach using artificial neural network and time series models for short term load forecasting*. R.D.; Electrical and Computer Engineering, 2003. IEEE CCECE 2003. Canadian Conference on , Volume: 3 , May 4-7, 2003. Pages: 1723 -1726.
- [3] ANEEL, 2001 - ANEEL (2001). *Manual dos Programas de Pesquisa e Desenvolvimento Tecnológico do Setor Elétrico Brasileiro*. ANEEL - Agência Nacional de Energia Elétrica, 47p.
- [4] BECCALI, et al. 2004 - M. Beccali , M. Cellura , V. Lo Brano and A. Marvuglia. *Forecasting daily urban electric load profiles using artificial neural networks*. Energy Conversion and Management, In Press, Corrected Proof, Available online 3 March 2004.
- [5] BISHOP, 1997 - C.M. Bishop. *Neural Networks for Pattern Recognition*. Oxford University Press, 1997.
- [6] CELESC, 2005 - CELESC. Home Page. *Centrais Elétricas de Santa Catarina S.A.* <http://celesc.com.br>, Fev/05.
- [7] DARBELLAY, et al., 2000 – G.A.Darbella, M.Slama. *Forecasting the short-term demand for electricity: Do neural networks stand a better chance?*, International Journal of Forecasting, Volume 16, Issue 1, January-March 2000, Pages: 71-83.
- [8] FERNANDES, Anita M. da Rocha. *Inteligência Artificial: noções gerais*. Florianópolis: Bookstore Livraria, 2003.
- [9] GRUAU & WHITLEY, 1993. Gruau, Frédéric; Whitley, Darrel. *Adding learning to the cellular development of neural networks: evolution and the baldwin effect*. Journal of Evolutionary Computation, 1(3). Pages: 213-233.
- [10] HOUCK, et al., 1996 – Houck CR, Joines JA, Kay MG. *A Genetic Algorithm for Function Optimization: A Matlab Implementation*, <http://www.ie.ncsu.edu/mirage/GAToolBox/gaot/>, acessado em Junho-2004.
- [11] HSU & CHEN, 2003 - Che-Chiang Hsu and Chia-Yon Chen. *Regional load forecasting in Taiwan—applications of artificial neural networks*. Energy Conversion and Management, Volume 44, Issue 12, July 2003, Pages: 1941-1949.

- [12] KANG, et al. 2004 - Chongqing Kang, Xu Cheng, Qing Xia, Yonghao Huang and Feng Gao. *Novel approach considering load-relative factors in short-term load forecasting*. Electric Power Systems Research, In Press, Corrected Proof, Available online 3 February 2004.
- [13] KATO, et al. 2002 - Kato, S.; Yukita, K.; Goto, Y.; Ichiyanagi, K. *Study of daily peak load forecasting by structured representation on genetic algorithms for function fitting*. Transmission and Distribution Conference and Exhibition 2002: Asia Pacific. IEEE/PES , Volume: 3 , 6-10 Oct. 2002. Pages: 1686 – 1690 v.3.
- [14] KHOTANZAD, et al., 1994 – A. Khotanzad, A. Abaye, D. Maratukulam. *An adaptive recurrent neural network system for multi-step-ahead hourly prediction of power system loads*. IEEE, 1994. Pages: 3393-3397.
- [15] LING, et al., 2003 – Ling, S.H.; Leung, F.H.F.; Lam, H.K.; Yim-Shu Lee; Tam, P.K.S. *A novel genetic-algorithm-based neural network for short-term load forecasting*. Industrial Electronics, IEEE Transactions on , Volume: 50 Issue: 4 , Aug. 2003. Pages: 793 -799.
- [16] LUGER, 2004 – Luger, George F. *Inteligência Artificial: estruturas e estratégias para a solução de problemas complexos*. Tradução da 4ª ed. Porto Alegre: Bookmann, 2004.
- [17] METAXIOTIS, et al., 2003 - K. Metaxiotis, A. Kagiannas, D. Askounis and J. Psarras. *Artificial intelligence in short term electric load forecasting: a state-of-the-art survey for the researcher*, Energy Conversion and Management, Volume 44, Issue 9, June 2003. Pages: 1525-1534.
- [18] MICHANOS, et al., 2003 – Michanos, S.P.; Tsakoums, A.C.; Fessas, P.; Vladov, S.S.; Mladenov, V.M. *Short-term load forecasting using a chaotic time series*. Signals, Circuits and Systems, 2003. SCS 2003. International Symposium on, Volume: 2 , July 10-11, 2003. Pages: 437-440.
- [19] MORETTIN & BUSSAB, 2002 – Morettin, Pedro A.; Bussab, Wilton de Oliveira. *Estatística Básica*. 5 ed. São Paulo: Saraiva, 2002. 526p.
- [20] OLIVEIRA, 1999 - Oliveira, C. M. de. *Um Modelo de Rede Neural Artificial para Previsão Automática da Carga Ativa Nodal de Curto Prazo em Sistemas de Transmissão e Distribuição de Energia Elétrica com Supervisão e Controle Automatizados*. Programa de Pós-Graduação em Engenharia de Produção. Florianópolis: UFSC, 1999. (Dissertação).
- [21] OLIVEIRA, 2004 - Oliveira, C. M. de. *Modelo Adaptativo para Previsão de Carga Ativa de Curto Prazo*. Florianópolis: UFSC, 2004. (Tese).
- [22] RUSSEL & NORVIG, 2004 – Russel, S; Norvig, P. *Inteligência Artificial*. Tradução da 2ª ed. Rio de Janeiro: Elsevier, 2004.

- [23] SILVA, et al., 2001. Alexandre P. Alves da Silva; U. P. Rodrigues; A. J. R. Reis; L. S. Moulin. *Oráculo: uma ferramenta para previsão de carga*. XVI SNPTEE (Seminário Nacional de Produção e Transmissão de Energia Elétrica). Campinas(SP): 2001.
- [24] TAMIMI, et al., 2000 – M. Tamimi and R. Egbert. *Short term electric load forecasting via fuzzy neural collaboration*. Electric Power Systems Research, Volume 56, Issue 3, 1 December 2000. Pages: 243-248.
- [25] TAO, et al., 2002 – D. Tao; W. Xiuli; W. Xifan. *A combined model of wavelet and neural network for short term load forecasting*. Power System Technology, 2002. Proceedings. PowerCon 2002. International Conference on, Volume: 4, 13-17 Oct. 2002. Pages: 2331 -2335 v.4.
- [26] TODESCO, et al., 2004 – J.L. Todesco; F.J.S. Pimentel; A.L.Bettiol. *O uso de famílias de circuitos e rede neural artificial para previsão de demanda de energia elétrica*. XXIV Encontro Nacional de Engenharia de Produção. Florianópolis, 2004.
- [27] WAZLAWICK, 1993 – Wazlawick, R. S. *Um modelo operatório para construção de conhecimento*. Programa de Pós-Graduação em Engenharia de Produção. Florianópolis: UFSC, 1993. (Tese).
- [28] WORAWIT & WANCHAI, 2002 - Worawit, T.; Wanchai, C.; *Substation short term load forecasting using neural network with genetic algorithm*. TENCON '02. Proceedings. 2002 IEEE Region 10 Conference on Computers, Communications, Control and Power Engineering , Volume: 3 , 28-31 Oct. 2002 . Pages: 1787 -1790 v.3.

## **9 ANEXOS**

## 9.1 Classificação das Variáveis da Função de Mutação em Grupo

```

[1] % TIPOS DAS VARIÁVEIS
[2] % CONJUNTO 1:  0 - NENHUM
[3] %              1 - AGORA
[4] %              2 - SEMANA
[5] %              3 - ANO
[6]
[7] % CONJUNTO 2:  0 - NENHUM
[8] %              1 - TEMPERATURA
[9] %              2 - UMIDADE
[10]
[11] % CONJUNTO 3:  0 - NENHUM
[12] %              1 - Atual
[13] %              2 - MeiaHoraAntes
[14] %              3 - UmaHoraAntes
[15] %              4 - DerivadaAtual
[16] %              5 - DerivadaMeiaHorasAntes
[17] %              6 - Derivada2Atual
[18] %              7 - Derivada2MeiHoraAntes
[19]
[20] TipoVariavel = [
[21]           0 0 0 % DiaDaSemana_sen, DiaDaSemana_cos,
[22]           0 0 0 % MeiasHorasDoDia_sen, MeiasHorasDoDia_cos,
[23] %           0 0 1 % AGORA_CargaMediaAtual,
[24]           0 0 2 % AGORA_CargaMediaMeiaHoraAntes,
[25]           0 0 3 % AGORA_CargaMediaUmaHoraAntes,
[26] %           0 0 4 % AGORA_DerivadaCargaAtual,
[27]           0 0 5 % AGORA_DerivadaCargaMeiaHoraAntes,
[28] %           0 0 6 % AGORA_Derivada2CargaAtual,
[29]           0 0 7 % AGORA_Derivada2CargaMeiaHoraAntes,
[30]           1 1 1 % AGORA_TemperaturaMediaAtual,
[31]           1 1 2 % AGORA_TemperaturaMediaMeiaHoraAntes,
[32]           1 1 3 % AGORA_TemperaturaMediaUmaHoraAntes,
[33]           1 1 4 % AGORA_DerivadaTemperaturaAtual,
[34]           1 1 5 % AGORA_DerivadaTemperaturaMeiaHoraAntes,
[35]           1 1 6 % AGORA_Derivada2TemperaturaAtual,
[36]           1 1 7 % AGORA_Derivada2TemperaturaMeiaHoraAntes,
[37]           1 2 1 % AGORA_UmidadeMediaAtual,
[38]           1 2 2 % AGORA_UmidadeMediaMeiaHoraAntes,
[39]           1 2 3 % AGORA_UmidadeMediaUmaHoraAntes,
[40]           1 2 4 % AGORA_DerivadaUmidadeAtual,
[41]           1 2 5 % AGORA_DerivadaUmidadeMeiaHoraAntes,
[42]           1 2 6 % AGORA_Derivada2UmidadeAtual,
[43]           1 2 7 % AGORA_Derivada2UmidadeMeiaHoraAntes,
[44]           1 1 0 % AGORA_TemperaturaMinimaDia,
[45]           1 1 0 % AGORA_TemperaturaMaximaDia,
[46]           1 1 0 % AGORA_TemperaturaMediaDia,
[47]           1 2 0 % AGORA_UmidadeMinimaDia,
[48]           1 2 0 % AGORA_UmidadeMaximaDia,
[49]           1 2 0 % AGORA_UmidadeMediaDia,
[50] %           0 0 0 % AGORA_CargaMinimaDia,
[51] %           0 0 0 % AGORA_CargaMaximaDia,
[52] %           0 0 0 % AGORA_CargaMediaDia,
[53]           0 0 1 % SEMANA_CargaMediaAtual,
[54]           0 0 2 % SEMANA_CargaMediaMeiaHoraAntes,
[55]           0 0 3 % SEMANA_CargaMediaUmaHoraAntes,
[56]           0 0 4 % SEMANA_DerivadaCargaAtual,
[57]           0 0 5 % SEMANA_DerivadaCargaMeiaHoraAntes,
[58]           0 0 6 % SEMANA_Derivada2CargaAtual,

```

```
[59]      0 0 7 % SEMANA_Derivada2CargaMeiaHoraAntes,
[60]      2 1 1 % SEMANA_TemperaturaMediaAtual,
[61]      2 1 2 % SEMANA_TemperaturaMediaMeiaHoraAntes,
[62]      2 1 3 % SEMANA_TemperaturaMediaUmaHoraAntes,
[63]      2 1 4 % SEMANA_DerivadaTemperaturaAtual,
[64]      2 1 5 % SEMANA_DerivadaTemperaturaMeiaHoraAntes,
[65]      2 1 6 % SEMANA_Derivada2TemperaturaAtual,
[66]      2 1 7 % SEMANA_Derivada2TemperaturaMeiaHoraAntes,
[67]      2 2 1 % SEMANA_UmidadeMediaAtual,
[68]      2 2 2 % SEMANA_UmidadeMediaMeiaHoraAntes,
[69]      2 2 3 % SEMANA_UmidadeMediaUmaHoraAntes,
[70]      2 2 4 % SEMANA_DerivadaUmidadeAtual,
[71]      2 2 5 % SEMANA_DerivadaUmidadeMeiaHoraAntes,
[72]      2 2 6 % SEMANA_Derivada2UmidadeAtual,
[73]      2 2 7 % SEMANA_Derivada2UmidadeMeiaHoraAntes,
[74]      2 1 0 % SEMANA_TemperaturaMinimaDia,
[75]      2 1 0 % SEMANA_TemperaturaMaximaDia,
[76]      2 1 0 % SEMANA_TemperaturaMediaDia,
[77]      2 2 0 % SEMANA_UmidadeMinimaDia,
[78]      2 2 0 % SEMANA_UmidadeMaximaDia,
[79]      2 2 0 % SEMANA_UmidadeMediaDia,
[80]      0 0 0 % SEMANA_CargaMinimaDia,
[81]      0 0 0 % SEMANA_CargaMaximaDia,
[82]      0 0 0 % SEMANA_CargaMediaDia,
[83]      0 0 1 % ANO_CargaMediaAtual,
[84]      0 0 2 % ANO_CargaMediaMeiaHoraAntes,
[85]      0 0 3 % ANO_CargaMediaUmaHoraAntes,
[86]      0 0 4 % ANO_DerivadaCargaAtual,
[87]      0 0 5 % ANO_DerivadaCargaMeiaHoraAntes,
[88]      0 0 6 % ANO_Derivada2CargaAtual,
[89]      0 0 7 % ANO_Derivada2CargaMeiaHoraAntes,
[90]      3 1 1 % ANO_TemperaturaMediaAtual,
[91]      3 1 2 % ANO_TemperaturaMediaMeiaHoraAntes,
[92]      3 1 3 % ANO_TemperaturaMediaUmaHoraAntes,
[93]      3 1 4 % ANO_DerivadaTemperaturaAtual,
[94]      3 1 5 % ANO_DerivadaTemperaturaMeiaHoraAntes,
[95]      3 1 6 % ANO_Derivada2TemperaturaAtual,
[96]      3 1 7 % ANO_Derivada2TemperaturaMeiaHoraAntes,
[97]      3 2 1 % ANO_UmidadeMediaAtual,
[98]      3 2 2 % ANO_UmidadeMediaMeiaHoraAntes,
[99]      3 2 3 % ANO_UmidadeMediaUmaHoraAntes
[100]     3 2 4 % ANO_DerivadaUmidadeAtual
[101]     3 2 5 % ANO_DerivadaUmidadeMeiaHoraAntes
[102]     3 2 6 % ANO_Derivada2UmidadeAtual
[103]     3 2 7 % ANO_Derivada2UmidadeMeiaHoraAntes
[104]     3 1 0 % ANO_TemperaturaMinimaDia
[105]     3 1 0 % ANO_TemperaturaMaximaDia
[106]     3 1 0 % ANO_TemperaturaMediaDia
[107]     3 2 0 % ANO_UmidadeMinimaDia
[108]     3 2 0 % ANO_UmidadeMaximaDia
[109]     3 2 0 % ANO_UmidadeMediaDia
[110]     0 0 0 % ANO_CargaMinimaDia
[111]     0 0 0 % ANO_CargaMaximaDia
[112]     0 0 0 % ANO_CargaMediaDia
[113] ];
```



## 9.2 Valores Referenciais

**Tabela – CELESC em números (Fonte: CELESC, 2005)**

Área de concessão	91,79% da área do Estado de SC
Número de clientes	1.962.914
Número de empregados	3.604
Número de usinas	12
Capacidade instalada nas usinas	82,77 MW
Número de subestações de transmissão	93
Número de subestações de distribuição	23
Subestações telecontroladas	72
Capacidade de transformação	4.366,07 MVA
Número de postes	1.286.650
Extensão de redes de transmissão	4.385,1 km
Extensão de redes de distribuição	94.056 km
Número de trafos de distribuição	121.898
Capacidade de transformação da distribuição	3.581,87 MVA

**Tabela – Valores de Carga Ativa (Fonte: Base de Dados do Projeto PCarga)**

Ponto	Carga Ativa Máxima	Carga Ativa Mínima	Carga Ativa Média	Desvio Padrão
TDE - Trindade	50.328534	10.189436	25.8954396	6.40297477
ICO - Centro da Ilha de Florianópolis	51.765	0	15.687617	9.3086589
INE - Norte da Ilha de Florianópolis	55.3118	5.205	18.3258268	6.21185132
ISS - Cidade de Itajaí	53.515	8.2608	35.7974538	5.70869326
SAD - Fábrica da Sadia no Oeste	19.750423	1.018615	12.464411	4.05987651
SRA - Seara no oeste de SC	15.5322	0.505037	10.5194948	2.50282104