

UNIVERSIDADE FEDERAL DO PAMPA

SÉRGIO BORDIGNON

**METODOLOGIA PARA PREVISÃO DE CARGA DE CURTÍSSIMO PRAZO
CONSIDERANDO VARIÁVEIS CLIMÁTICAS E AUXILIANDO NA
PROGRAMAÇÃO DE DESPACHO DE PEQUENAS CENTRAIS HIDRELÉTRICAS**

**Alegrete
2012**

SÉRGIO BORDIGNON

**METODOLOGIA PARA PREVISÃO DE CARGA DE CURTÍSSIMO PRAZO
CONSIDERANDO VARIÁVEIS CLIMÁTICAS E AUXILIANDO NA
PROGRAMAÇÃO DE DESPACHO DE PEQUENAS CENTRAIS HIDRELÉTRICAS**

Dissertação apresentada ao Programa de Pós-graduação *Stricto Sensu* em Engenharia Elétrica da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Daniel Pinheiro Bernardon

Co-orientador: Prof. Dr. Maurício Sperandio

**Alegrete
2012**

CIP – Catalogação na Publicação

B729m Bordignon, Sérgio

Metodologia para precisão de carga de curtíssimo prazo considerando variáveis climáticas e auxiliando na programação de despacho de pequenas centrais hidrelétricas / Sérgio Bordignon ; orientador, Daniel Pinheiro Bernardon ; co-orientador Maurício Sperandio. – Alegrete, 2012.

115 p. : il. ; 21 cm.

Dissertação (Mestrado) – Universidade Federal de Pampa, Programa de Pós-Graduação em Engenharia Elétrica, 2012.

1. Energia elétrica. 2. Pequenas Centrais Hidrelétricas. 3. Sistemas de energia elétrica. I. Bernardon, Daniel Pinheiro, orient. II. Título.

CDU: 621.31

Ficha elaborada pela bibliotecária Marlucy Veleda Farias - CRB 10/2067

SÉRGIO BORDIGNON

**METODOLOGIA PARA PREVISÃO DE CARGA DE CURTÍSSIMO
PRAZO CONSIDERANDO VARIÁVEIS CLIMÁTICAS E AUXILIANDO
NA PROGRAMAÇÃO DE DESPACHO DE PEQUENAS CENTRAIS
HIDRELÉTRICAS**

Dissertação apresentada ao Programa de Pós-graduação *Stricto Sensu* em Engenharia Elétrica da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Mestre em Engenharia Elétrica.

Área de concentração: Sistemas de Energia

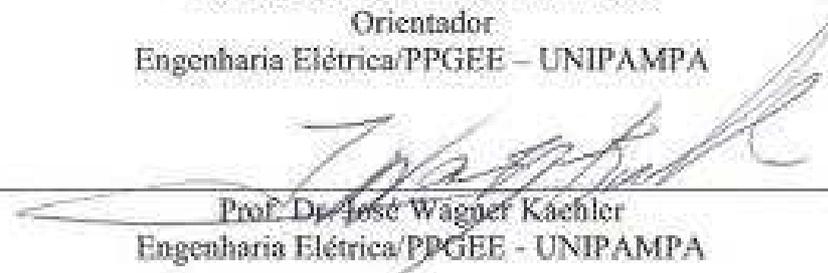
Dissertação defendida e aprovada em: 29 de junho de 2012.
Banca examinadora:



Prof. Dr. Daniel Pinheiro Bernardon

Orientador

Engenharia Elétrica/PPGEE – UNIPAMPA



Prof. Dr. José Wagner Käehler

Engenharia Elétrica/PPGEE - UNIPAMPA



Prof. Dr. Tiago Bandeira Marchesan

Engenharia Elétrica/PPGEE - UFSM

Dedico a minha esposa Luciane e ao meu filho Vinícius, que estão sempre ao meu lado em todos os momentos, sejam eles bons ou de dificuldades.

AGRADECIMENTOS

Agradeço, primeiramente, a Deus, por me guiar e iluminar nos momentos difíceis desta caminhada.

Agradeço a minha esposa Luciane e ao meu filho Vinícius, pelo amor, carinho, compreensão, incentivo e por estarem ao meu lado em todas as horas, acreditando e apoiando as minhas escolhas.

Agradeço a minha mãe Joyce, meu pai José Ricardo (em memória) e minhas irmãs, Solange e Clairê, pela estrutura familiar que me deu sabedoria e força para enfrentar os desafios da caminhada e chegar à beleza desta conquista.

Aos meus sogros, Valsir e Dionéia, pela ajuda e apoio dado, sobretudo nos momentos em que tive que me ausentar do lar.

Agradecimento especial ao meu orientador Prof. Dr. Daniel Pinheiro Bernardon, pelos momentos de conhecimento e compreensão e pela dedicação em me ajudar a concluir esse importante processo. Ao meu co-orientador Prof. Dr. Maurício Sperandio pelas valorosas contribuições para o desenvolvimento deste trabalho.

Agradecimento igualmente especial ao Prof. Dr. Vinícius Jacques Garcia, por suas contribuições e pelas “tardes festivas” de sexta-feira.

Aos meus colegas de mestrado, Franciele, Adir, Diego, Marcelo, Everson, Cleverton, Marthielo, Durgante e Wagner, pelo companheirismo durante a fase de créditos.

Aos diretores da Mux Energia, Sr. Mário Atílio Marin e Sr. Alexandre Zanini pelo apoio que me deram e aos demais colegas de trabalho pela compreensão.

A todos os meus amigos que vibram com minhas conquistas e me ajudam a enfrentar e vencer minhas dificuldades.

“Que vossos esforços desafiem as impossibilidades. Lembrai-vos de que as grandes coisas do homem foram conquistadas do que parecia impossível”.

Charles Chaplin

RESUMO

A previsão de carga é uma atividade de grande importância no Setor Elétrico, tendo em vista que a maioria dos estudos de planejamento e operação dos sistemas elétricos necessita de uma boa estimativa da carga a ser atendida. Na literatura encontram-se diversas metodologias para projeção de carga elétrica nos distintos horizontes de planejamento, porém limitadas a sistemas elétricos de médio e grande porte e poucas são as propostas de projeção de demanda no horizonte de curtíssimo prazo, principalmente para pequenas empresas do Setor Elétrico.

O objetivo deste trabalho é apresentar uma metodologia inovadora de previsão de carga, a curtíssimo prazo, que considere as influências das condições climáticas e que possa auxiliar na programação do regime de operação de uma Pequena Central Hidrelétrica (PCH), principalmente em épocas de estiagem, quando a disponibilidade de água é restrita. A metodologia proposta envolve a criação de um modelo probabilístico discreto (cadeia de Markov) a partir da classificação dos dados históricos em um Mapa Auto-Organizável (SOM). Assim, é possível se estimar a probabilidade de um determinado nível de demanda acontecer dada uma condição climática atual, bem como o número de intervalos de tempo (horas) até que isso aconteça. Com estas informações é possível elaborar a melhor agenda de funcionamento da PCH de forma que a mesma esteja em funcionamento nos momentos em que a demanda atingir os valores máximos.

O método proposto apresenta como diferencial em relação aos demais métodos existentes o fato de considerar a influência das variáveis climáticas (temperatura, umidade relativa do ar e velocidade do vento) para a previsão de demanda de energia elétrica no curtíssimo prazo, além de que os valores de entrada de demanda de energia e das variáveis climáticas (temperatura e umidade relativa do ar) são obtidos em tempo real, através de um sistema SCADA.

Esta metodologia foi aplicada utilizando-se os dados reais de uma pequena concessionária de distribuição de energia elétrica do Rio Grande do Sul, mostrando resultados satisfatórios, suficientes para permitir a sua aplicação prática.

Palavras-chave: Despacho de PCH. Previsão de demanda. Curtíssimo prazo. Influências climáticas. Mapas Auto-Organizáveis.

ABSTRACT

The electrical charge forecast is an activity of great importance in the Electricity Sector, considering that most studies of electrical systems planning and operation require a good estimative of the charge to be fulfilled. In books, there are various methodologies to have the electrical charge projection in different planning horizons, but limited to medium and large electrical systems. Furthermore, there are only a few demand projection proposals in the very short-term horizon, especially for small Electricity Sector companies.

The aim of this paper is to present an innovative methodology in order to have the charge forecast, in a very short-term, which considers the climatic conditions influence and is able to assist the operation system programming of a Small Hydroelectric Power Plant, particularly in times of drought when water availability is restricted. The proposed methodology involves creating a discrete probabilistic pattern (Markov chain) from the historical data classification in a Self-Organizing Map (SOM). It is therefore possible to estimate the probability of reaching a certain demand level, taking the current climatic condition, as well as the periods of time (hours) until it happens. With this information it is possible to develop the best plant operation schedule so that it operates when the demand reaches its maximum numbers.

The proposed method presents as differentials upon the other existing methods, the fact of considering the climatic variables influence (temperature, air humidity and wind speed) to forecast electricity demand in the very short-term, as well as the energy demand input values and climate variables obtainment (temperature and air humidity) in real time via a SCADA system.

This methodology was applied using real data from a small electricity distribution plant in Rio Grande do Sul, showing satisfactory results, enough to allow their practical application.

Keywords: Small Hydroelectric Power Plant Release. Demand Forecast. Very short-term. Climatic Influences. Self-Organizing Maps.

LISTA DE FIGURAS

Figura 1 - Fluxograma para a construção de um modelo de Regressão Dinâmica ..	45
Figura 2 - Modelo de um neurônio biológico.....	52
Figura 3 - Modelo de um neurônio artificial.....	52
Figura 4 – Modelo de um neurônio (aperfeiçoado).	53
Figura 5 - Aprendizado supervisionado de uma RNA.....	55
Figura 6 - Uma transformação $\Phi: E \rightarrow S$ em um mapa 4x4 com conexões hexagonais.	59
Figura 7 - Mapa ou rede hexagonal com 16 modelos (4x4).....	60
Figura 8 - Sistema de Inferência Fuzzy.	63
Figura 9 - Fuzzyficação.....	63
Figura 10 - Estrutura de um sistema ANFIS.	66
Figura 11 - Diagrama de relações causais que influenciam a demanda de energia elétrica.	70
Figura 12 - Perfis de carga típicos para um dia útil e domingo.	71
Figura 13 - Regressão entre a temperatura média e a demanda de energia.	72
Figura 14 - Regressão entre a umidade média e a demanda de energia.	73
Figura 15 - Variação do ID, temperatura e umidade ao longo de 100 horas.	75
Figura 16 - Regressão entre a velocidade do vento e a demanda elétrica.....	76
Figura 17 - Variação da ST, da TA e da VV ao longo de 100 horas.	77
Figura 18 - Variação da ST em função do ID e diferença para a temperatura ambiente ao longo de 100 horas.	78
Figura 19 - Fluxograma da metodologia de previsão de demanda.....	80
Figura 20 – Estrutura do sistema SCADA para aquisição dos dados.....	81
Figura 21 - Mapas componentes 6x6 para as quatro variáveis estudadas.....	82
Figura 22 – Mapas componentes 20x20 para as quatro variáveis estudadas.	83
Figura 23 - Mapa componente 20x20 para sensação térmica.	84
Figura 24 - Diagrama de estados de uma cadeia de Markov com a matriz de transição da Tabela 3.	86
Figura 25 - Mapa 4x4 com os dados da Tabela 4.....	88
Figura 26 - Transições entre neurônios conforme seqüência de dados amostrados.	89
Figura 27 - Modelo de Markov criado a partir do mapa da Figura 25.	90
Figura 28 – Evolução da geração da PCH entre set-2008 e ago-2009.	91
Figura 29 – Projeção de cenários para cálculo de probabilidade para um dia de setembro.....	93
Figura 30 – Projeção de demanda para um dia de setembro.	94
Figura 31 – Fluxograma da metodologia de despacho da PCH	95
Figura 32 – Projeção de demanda para um dia útil de dez. 2011.....	98
Figura 33 - Perfil de demanda para um dia útil de dez. 2011.	99
Figura 40 – Comparativo das Demandas com e sem o agendamento do despacho da PCH.	105
Figura 41 – Demandas do mês de dezembro após o agendamento do despacho da PCH.	106

LISTA DE TABELAS

Tabela 1- Categorias dos índices de desconforto térmico.....	74
Tabela 2 - Dados agrupados por um dos neurônios da Figura 22.....	84
Tabela 3 - Exemplo de uma matriz de transição (P) para dois estados de demanda.	86
Tabela 4 -Exemplo de medidas horárias para as quatro variáveis observadas.....	88
Tabela 5 - Agenda de despacho da PCH	102

LISTA DE SIGLAS

ANEEL – Agência Nacional de Energia Elétrica
ANFIS – Sistema Adaptativo de Interferência Fuzzy
ANNSTLF – *Artificial Neural Network Short-Term Load Forecaster*
AR – Modelo Auto-Regressivo
ARIMA – Modelo Auto-Regressivo Integrado de Médias Móveis
ARIMAX – Modelo Auto-Regressivo de Médias Móveis e Entrada Auxiliar
ARMA – Modelo Auto-Regressivo de Médias Móveis
ARMAX – Modelo Auto-Regressivo de Médias Moveis e Entrada Auxiliar
AT – Alta Tensão
BT – Baixa Tensão
EPRI – *Electrical Power Research Institute*
FALCON – *Fuzzy Adaptive Learning Control*
FPW – *Forecast Pro for Windows*
GB – Giga-Byte
GHz – Giga-Hertz
GM – Modelo Grey
GMRAE – *Geometric Mean Relative Absolute Error*
IA – Inteligência Artificial
IAG-USP – Instituto de Astronomia, Geofísica e Ciências Atmosféricas da Universidade de São Paulo
ID – Índice de Desconforto
IEEE – *Institute of Electrical and Electronics Engineers*
MA – Médias Móveis
MAPE – *Mean Absolute Percentual Error*
MB – Mega-Byte
MLP – Perceptron de Multiplas Camadas
MLR – Regressão Multipla Linear
MT – Média Tensão
MUST – Montante de Uso do Sistema de Transmissão
MW – Mega-Watt
ONS – Operador Nacional do Sistema Elétrico

PCH – Pequena Central Hidrelétrica
PPGEE – Programa de Pós Graduação em Engenharia Elétrica.
RAM – *Random Access Memory*
RBF – Função de Base Radial
RD – Regressão Dinâmica
RNA – Redes Neurais Artificiais
SARIMA – Modelos ARIMA Sazonal
SCADA – *Supervisory Control and Data Acquisition*
SE – Sistemas Especialistas
SIN – Sistema Interligado Nacional
SOM – *Self-Organizing Map* (Mapa Auto-Organizável)
ST – Sensação Térmica
SVM – Máquinas de Vetores de Suporte
SVR – Máquinas de Vetor Suporte para Regressão
TA – Temperatura Ambiente
UFES – Universidade Federal de Santa Maria
UNIPAMPA – Universidade Federal do Pampa
UR – Umidade Relativa do Ar
VV – Velocidade do Vento

LISTA DE SÍMBOLOS

$\varphi(B)$ – Polinômio Auto-Regressivo

Y_t - variável dependente (exógena) no instante t

X_t - vetor de variáveis causais (exógenas)

β - vetor de coeficientes das variáveis causais

ε_t - o ruído aleatório associado ao modelo

B - operador de defasagem

$\varphi(\bullet)$ - função de ativação

w_j - o peso atribuído à j

b - limiar de ativação do neurônio

v - variável de entrada da função de ativação do neurônio

y - saída do neurônio

Φ - transformação não-linear

E - espaço de entrada contínuo

S - espaço de saída discreto

P – matriz de transição (Markov)

$P(n)$ – Vetor com as probabilidades de cada estado

$P(0)$ – Vetor com as probabilidades do estado inicial

n – número de intervalos de tempo após o estado inicial

Em – erro médio

L_i - i -ésimo valor da carga real

\hat{L}_i - i -ésimo valor da carga projetada.

SUMÁRIO

1 INTRODUÇÃO	25
1.1 Objetivo	28
1.2 Estrutura do Trabalho	29
2 REVISÃO BIBLIOGRÁFICA	31
2.1 Previsão de Demanda	31
2.2 Influências de Variáveis Climáticas	35
2.3 Despacho de Usinas Hidrelétricas.....	38
3 MÉTODOS DE PREVISÃO DE DEMANDA	41
3.1 Classificação dos métodos segundo o horizonte de projeção	41
3.1.1 Métodos de Projeção de Médio e Longo Prazo	41
3.1.2 Métodos de Projeção de Curto e Curtíssimo Prazo	42
3.2 Modelos de séries temporais	43
3.3 Modelos de regressão dinâmica	44
3.3.1 Construção dos modelos de RD	46
3.3.2 Testes usados nos modelos de RD	47
3.3.3 Exemplo de aplicação	48
3.4 Redes neurais artificiais	50
3.4.1 Neurônio biológico.....	51
3.4.2 Neurônio artificial.....	52
3.4.3 Arquitetura das RNAs	54
3.4.4 Aprendizagem de RNAs.....	55
3.4.5 Algoritmo de treinamento.....	56
3.4.6 Perceptron multicamadas (MLP).....	56
3.4.7 Controle de generalização.....	57
3.4.8 Procedimento para a RNA	57
3.4.9 Mapas Auto-Organizáveis – SOM (Self-Organizing Map).....	58
3.5 Lógica Fuzzy	62
3.6 Redes Neuro-Fuzzy	64
3.6.1 Adaptive Network Fuzzy Inference System (ANFIS).....	65
4 ANÁLISE DA INFLUÊNCIA DAS VARIÁVEIS CLIMÁTICAS NA PREVISÃO DE DEMANDA A CURTÍSSIMO PRAZO	69
4.1 Determinação dos padrões de carga elétrica	70

4.2 Relação entre demanda, temperatura ambiente e umidade relativa do ar ..	71
4.3 Índice de desconforto.....	73
4.4 Sensação térmica	75
5 METODOLOGIA PROPOSTA.....	79
5.1 Aplicação do SOM na metodologia proposta.....	81
5.2 Construção do modelo de Markov para previsão de carga	85
5.2.1 Exemplo de um modelo de previsão de demanda	86
5.3 Atribuição de estados a partir do SOM.....	87
5.3.1 Cálculo do desvio das previsões de carga.....	90
5.4 Programação do despacho da PCH	91
6 ANÁLISES EXPERIMENTAIS	97
6.1 Previsor de demanda.....	97
6.2 Agenda de despacho da PCH.....	100
7 CONCLUSÕES E TRABALHOS FUTUROS	107
7.1 Conclusões gerais.....	107
7.2 Trabalhos publicados e apresentados em eventos científicos	108
7.3 Sugestões para Trabalhos Futuros.....	110
REFERENCIAS BIBLIOGRÁFICAS	111

1 INTRODUÇÃO

A projeção de demanda de energia elétrica pode ser vista como uma das principais atividades estratégicas dentro da complexa estrutura envolvida no planejamento da operação e expansão, programação da operação e confiabilidade dos sistemas elétricos de potência. Estudos em sistemas de energia elétrica como o despacho econômico, fluxo de potência e estabilidade transitória e os planejamentos de geração, transmissão, expansão e de compra e venda de energia, necessitam da previsão de cargas elétricas (ALTRAN, 2010).

A estimação do comportamento futuro das cargas presentes em um circuito alimentador e, de forma mais abrangente, dentro da área de concessão de uma determinada empresa de distribuição de energia elétrica, está diretamente vinculada à tarefa de tomada de decisão voltada à gestão tanto pelo lado da demanda quanto da oferta de energia. Os horizontes de previsão podem variar de alguns minutos a vários anos ou décadas. De acordo com Andrade (2010) existem objetivos particulares no que se refere a cada um destes horizontes de previsão. Desta forma a previsão de demanda de energia pode ser classificada em previsão de longo prazo, previsão de médio prazo, previsão de curto prazo e previsão de curtíssimo prazo (MURTO, 1998; SWARUP; SATISH, 2002; AL-KANDARI et al, 2004; YALCINOZ; EMINOGLU, 2005). Para cada um dos horizontes de previsão existe uma abordagem e um objetivo específico.

Previsões de demanda de longo prazo têm como horizonte anos ou décadas e o objetivo é fornecer para os produtores e distribuidores a evolução da demanda, permitindo a definição de estratégias para o aumento da capacidade de atendimento do mercado consumidor, com a construção de novas plantas produtoras ou aumentando a capacidade das linhas de transmissão.

Previsões de demanda de médio prazo são aquelas com horizonte de algumas semanas ou meses. Sua principal aplicação é na otimização da alocação de máquinas geradoras, com o objetivo de se ter uma operação econômica. Este horizonte de previsão também é muito útil para se executar estudos elétricos de situações de instabilidade da rede elétrica, objetivando manter uma segurança do sistema. Planejamento de manutenção nas redes, pesquisas de mercado para produtores e revendedores, planejamento na compra de combustíveis, negociações

mais vantajosas de contratos com outras empresas e redução dos riscos financeiros também se utilizam da previsão de médio prazo (ROMERA et al, 2008).

Nas previsões de demanda de curto prazo o horizonte é de horas ou dias à frente, e tem por finalidade uma alocação econômica dos geradores, observando restrições operativas, de maneira que o custo da produção de energia elétrica seja menor.

Já nas previsões de demanda de curtíssimo prazo, o horizonte é de poucos minutos até algumas horas. Esta previsão tenta exprimir com maior exatidão o perfil instantâneo da carga sendo forte subsídio para o processo decisório de maior disponibilidade de potência, bem como um efetivo gerenciamento da carga de demanda, assumindo assim, fundamental importância no processo de realocação de manutenções de unidades geradoras, partidas de novas unidades geradoras para atendimento à demanda, realocação de folgas de potência entre empresas, visando otimizar o uso de potência em função da diversidade da carga e gerenciamento da demanda no período de ponta.

Deste modo, uma projeção com escopo divergente do horizonte de estudo (curtíssimo, curto, médio ou longo prazos) pode trazer inúmeros prejuízos, já que uma subestimação pode causar falhas no fornecimento e resultar em não atendimento de consumidores e uma superestimação conduz a uma ociosidade do sistema envolvido (PAI et. al, 2005).

Neste contexto, a utilização de metodologias que permitem prever o comportamento das cargas de um dado sistema mostra-se relevante. Como foi descrito por Campos (2008), na literatura encontram-se diversas metodologias para a projeção de carga elétrica nos distintos horizontes de planejamento. No entanto, a aplicação, em geral, das metodologias limitam-se a sistemas elétricos de médio e grande porte considerando o curto, médio e longo prazo e poucas são as propostas de projeção de demanda no horizonte de curtíssimo prazo, de grande importância e utilização, principalmente para pequenas concessionárias, permissionárias e cooperativas de distribuição de energia elétrica.

Para estas empresas, o desafio de prever a demanda de energia elétrica de forma eficiente, independente do horizonte de previsão, se torna ainda maior, pois apresentam como característica, a grande sensibilidade das cargas. Por exemplo, a entrada ou saída de funcionamento de uma única empresa já tem impacto significativo na demanda.

Como, normalmente, a maior parte da energia elétrica distribuída por elas é adquirida de outras distribuidoras de maior porte, através de contratos de fornecimento de energia elétrica com valores de demanda contratada, que preveem valor monetário adicional por ultrapassagem do valor contratado, e o restante da energia distribuída é gerada em Pequenas Centrais Hidrelétricas (PCH's), a aplicação de um método adequado de previsão de carga, a curtíssimo prazo, é de significativa importância, já que pode, entre outras aplicações, auxiliar na definição do regime de operação das PCH's, sobretudo em períodos de estiagem, quando há restrição na geração de energia.

Enfatiza-se que os métodos utilizados para previsão de carga possuem um desempenho fortemente associado à confiabilidade de dados históricos de diferentes grandezas. Independente da técnica de estimação utilizada, sua capacidade de previsão depende do nível de conhecimento do comportamento passado do sistema.

Diversos fatores podem influenciar na análise e na modelagem da carga, tais como: condições meteorológicas (velocidade do vento, umidade relativa do ar, temperatura ambiente) e fatores diversos (feriados e finais de semana). Uma boa análise desses fatores permite influenciar de maneira direta nos resultados das previsões, pois admitem uma maior abstração para que sirvam de entrada para um sistema previsor (MURTO, 1998; SWARUP; SATISH, 2002).

Na previsão de demanda de energia elétrica a curtíssimo prazo, as variáveis climáticas apresentam um impacto importante nas projeções e devem ser incorporadas no modelo de forma a melhorar os resultados. Um aspecto importante diretamente relacionado ao consumo de energia elétrica é o conforto térmico dos indivíduos, ou seja, a sensação de satisfação térmica com o ambiente que envolve esse consumidor. Assim, as mudanças nas condições climáticas (temperatura ambiente, velocidade do vento, umidade relativa, entre outras) afetam o metabolismo do corpo humano mudando essa sensação de conforto dos indivíduos. Diante disso, para controle da sensação de conforto, muitos indivíduos fazem uso de condicionadores de ar. No Brasil, esse equipamento é um dos principais responsáveis pela elevação de consumo de energia elétrica nos ambientes comerciais e residenciais.

1.1 Objetivo

O objetivo principal deste trabalho é o desenvolvimento de um Sistema de Projeção de Demanda de Energia Elétrica a Curtíssimo Prazo que considere a variação das condições climáticas e possa ser aplicado para auxiliar na definição do regime de operação de uma PCH instalada em uma rede de distribuição. Neste contexto, este trabalho visa apresentar as pesquisas e os resultados de avaliação que sustentam o desenvolvimento da metodologia proposta de previsão de carga de curtíssimo prazo. A metodologia baseia-se nas relações causa-efeito das principais variáveis climáticas com a demanda de energia elétrica, bem como o uso de Mapas Auto-Organizáveis (SOM) e modelo probabilístico discreto (cadeia de Markov) para realização das previsões.

A Temperatura Ambiente (TA) e a Umidade Relativa do ar (UR) são relacionadas através do Índice de Desconforto (ID), enquanto que a TA juntamente com a Velocidade do Vento (VV), encontram-se vinculadas através da Sensação Térmica (ST) dos indivíduos. Identificou-se a partir deste trabalho que tanto o ID quanto a ST são indicadores adequados à projeção de demanda de energia elétrica a curtíssimo prazo, dado que consideram satisfatoriamente os efeitos das principais variáveis climáticas sobre a evolução da demanda de energia elétrica.

Já o SOM é usado para agrupar os valores de demanda e variáveis climáticas em neurônios, de forma que padrões similares fiquem em neurônios contíguos, tendo uma organização topológica. Ele também permite extrair as relações abstratas entre as variáveis por meio da sua posição nos mapas componentes, permitindo verificar a correlação entre elas. Finalmente, a criação do modelo de Markov é usada para realizar as análises da evolução dos estados ao longo do tempo. Desta forma, se tivermos uma condição inicial de demanda e variáveis climáticas, o SOM aloca este vetor de dados em um neurônio e o modelo de Markov indica probabilidade de transições dos neurônios ao longo do tempo, fornecendo o percentual de alteração de demanda com sua respectiva probabilidade de ocorrer, permitindo assim a realização das previsões de carga de curtíssimo prazo.

Com vista a atingir o objetivo principal, os seguintes objetivos parciais foram propostos:

- Obtenção das curvas de demanda de energia elétrica na área de concessão de uma pequena concessionária de distribuição de energia elétrica. As curvas

serão avaliadas para os diferentes dias da semana (dias úteis, sábados, domingos) e períodos do ano (estações do ano);

- Levantamento dos dados relacionados às principais variáveis climáticas que serão utilizadas nas pesquisas de projeção de demanda, a saber: valor da temperatura ambiente, valor da umidade relativa do ar e valor da velocidade média do vento;
- Modelagem das relações “causa-efeito” entre as variáveis climáticas mensuradas e a demanda de energia elétrica;
- Criação dos Mapas Auto-Organizáveis – SOM (*Self-Organizing Map*) para agrupamento da demanda e variáveis climáticas em neurônios;
- Criação de modelo probabilístico discreto (cadeia de Markov) a partir da classificação de dados históricos do SOM para realização das previsões de carga;
- Desenvolvimento de ferramenta computacional para realização das previsões de carga de curtíssimo prazo com base na metodologia proposta;
- Avaliação dos resultados obtidos através da comparação da demanda projetada com a demanda real medida.
- Elaboração da programação de operação da PCH de forma a garantir que a mesma esteja em funcionamento nos momentos em que a demanda atingir os valores máximos.

1.2 Estrutura do Trabalho

Este trabalho está organizado em sete capítulos os quais buscam, de forma significativa, o bom entendimento da pesquisa realizada. No capítulo 1 é apresentado o problema, os objetivos deste trabalho e a forma como foi estruturado.

No capítulo 2 é realizada uma revisão bibliográfica contendo de forma resumida e geral os conceitos envolvidos no âmbito da previsão de demanda, com ênfase no curtíssimo prazo, a influência das variáveis climáticas na previsão da demanda e o despacho de PCH's.

No capítulo 3 é apresentada a classificação dos métodos de previsão de carga segundo o horizonte de projeção e os modelos mais usuais para previsão de demanda como, modelo de séries temporais, de regressão dinâmica, redes neurais

artificiais, incluindo os conceitos de Mapas Auto-Organizáveis (SOM), lógica Fuzzy e redes Neuro-Fuzzy.

Uma análise das influências das variáveis climáticas (temperatura ambiente, Umidade relativa do ar, velocidade do vento) na evolução da demanda de energia elétrica, é realizada no capítulo 4. Os conceitos de Índice de Desconforto e Sensação Térmica e suas influências na demanda de energia elétrica, também são analisados neste capítulo.

No capítulo 5 é apresentada a aplicação da metodologia desenvolvida para previsão de demanda a curtíssimo prazo, com a utilização de Mapas Auto-Organizáveis (SOM) e Modelo Probabilístico de Markov, levando em consideração a influência das condições climáticas. Também é apresentada a aplicação desta metodologia para auxiliar na programação de despacho da PCH.

No capítulo 6 são apresentados os resultados de testes experimentais em um protótipo do previsor de carga, utilizando dados reais de uma pequena concessionária de distribuição de energia elétrica do Rio Grande do Sul, com o objetivo de validar o método desenvolvido. Também são realizados testes envolvendo as previsões obtidas para elaborar a programação de funcionamento da PCH em uma época de estiagem, a fim de verificar a aplicabilidade da metodologia para evitar a ultrapassagem da demanda contratada.

No capítulo 7 são apresentadas as conclusões gerais desta pesquisa, os trabalhos referentes ao tema que foram publicados em congressos e simpósios e algumas sugestões para trabalhos futuros. Por fim, são relacionadas às referências bibliográficas utilizadas.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta uma breve visão dos trabalhos que vem sendo propostos durante as últimas décadas, tanto no Brasil como em outros países, na área de previsão de demanda de energia elétrica, sobretudo no curtíssimo prazo, a influência das variáveis climáticas na previsão de demanda e o despacho de PCH's.

2.1 Previsão de Demanda

Como visto no Capítulo 1, a previsão de demanda pode ser desmembrada em quatro tipos: curtíssimo prazo, curto prazo, médio prazo e longo prazo, classificados conforme o período de previsão. Para a previsão a curtíssimo prazo, que é o objetivo principal deste trabalho, o horizonte projetado é de alguns minutos até algumas horas à frente.

Nas últimas décadas foram desenvolvidos vários métodos para previsão de cargas. É possível encontrar na literatura uma grande quantidade de trabalhos envolvendo previsão de cargas elétricas, muitos deles utilizam métodos que necessitam da modelagem matemática da carga como: regressão linear múltipla ou simples, alisamento exponencial, estimação de estado, filtro de Kalman, métodos ARIMA de Box e Jenkins (BOX; JENKINS, 1976; O'DONOVAN, 1983).

Papalexopoulos e Hesterberg (1990) criaram um modelo baseado em regressão linear para ser usado na previsão de demanda de energia elétrica no curto prazo. Esse modelo foi aplicado em uma empresa americana do ramo de geração e distribuição de energia elétrica e o seu desempenho foi bem superior ao modelo anteriormente empregado.

Engle, Mustafa e Rice (1992) apresentaram vários modelos de regressão para a previsão de um dia à frente do pico de carga. Seus modelos incorporam influências determinísticas: feriados; influências estocásticas: média da carga; influência exógena: condições meteorológica. Outras referências tais como: Haida e Muto (1994); Hyde e Hodnett (1997); Ruzic, Vuckovic e Nikolic (1998); Charytoniuk e Chen (2000); descrevem outras aplicações dos modelos de regressão para previsão de carga.

Estes métodos clássicos não são tão triviais de serem analisados e modelados, além de exigirem muito esforço computacional que pode influenciar no resultado final elevar a complexidade da análise (CAMPOS, 2010).

Nas últimas décadas foram desenvolvidos vários métodos para previsão de carga. Uma variedade de métodos utilizando Redes Neurais, Logica Fuzzy, sistemas especialistas e algoritmos de aprendizagem estatísticos são usados para diversos tipos de previsão (DE GOOIJER; HYNDMAN, 2006).

Charytoniuk e Chen (2000) desenvolveram um método de previsão no curtíssimo prazo para ser utilizado num sistema de gerenciamento de energia de uma empresa americana. Segundo seu trabalho, quando empregadas redes neurais artificiais na solução deste tipo de problema, são apresentadas informações de tempo, carga e dados meteorológicos para se estimar a demanda futura. Seu trabalho reduziu as entradas das redes neurais artificiais apenas para o que eles chamaram de incremento relativo de previsão, que consiste na diferença entre duas medidas consecutivas divididas pela primeira delas. Os autores classificaram a previsão de demanda de energia no curtíssimo prazo como necessária para determinar a melhor estratégia para a utilização de recursos de grande importância no mercado desregulamentado de energia.

Trudnowsk et al. (2001) empregou estimadores de Kalman para a previsão com frequência de 5 minutos e horizonte de duas horas com considerável precisão e baixa sensibilidade.

Cottet e Smith (2003) propuseram um modelo regressivo de equações múltiplas, com um vetor auto-regressivo estacionário diagonal de primeira ordem, para previsão de carga de energia elétrica com frequência de meia hora. Os autores afirmaram que modelar e prever carga que ocorrem durante o curso de um dia é uma atividade chave na indústria de eletricidade. Citaram também que, na Inglaterra, o regulador do mercado de energia penaliza os participantes que não fazem uma previsão precisa.

Taylor (2003) estendeu a formulação exponencial de Holt-Winters para acomodar duas sazonalidades e corrigiu a auto-correlação residual usando um modelo auto-regressivo simples, para realizar a previsão no curto e no curtíssimo prazo. O autor conclui que seus resultados ficaram muito próximos dos outros métodos utilizados, com desempenho levemente melhor para o método desenvolvido por ele.

Segundo Kawauchi et al. (2004), previsões precisas de demanda de energia elétrica no curtíssimo prazo são indispensáveis para evitar distúrbios nos centros de distribuição que, procuram minimizar as flutuações entre a demanda e o fornecimento ajustando continuamente a geração de energia elétrica. Este trabalho apresentou um método, baseado na teoria do caos, para previsão de passos de 30 segundos e horizonte de 10 minutos. Os autores apresentaram gráficos ilustrando os erros obtidos e concluíram que os resultados foram bons para previsão de vários passos à frente.

Falco (2005) pesquisou os métodos univariados convencionais: Holt-Winters e Box & Jenkins, considerando suas formulações aperfeiçoadas e adaptadas às características próprias do tipo de série em questão, para realizar a previsão do consumo de carga horária. Comparou estes métodos univariados com o software *Artificial Neural Network Short-Term Load Forecaster (ANNSTLF)*, produzido pelo *Electrical Power Research Institute (EPRI/EUA)*, utilizado pelo Operador Nacional do Sistema Elétrico Brasileiro (ONS) apontando como vantagem do seu método, a interpretabilidade das informações obtidas.

Yang et al. (2006) empregaram um sistema neural Fuzzy para previsão de demanda de energia elétrica no curtíssimo prazo. Eles afirmaram que, embora a previsão de demanda de energia receber atenção crescente, poucos trabalhos estudaram a previsão de demanda de energia elétrica no curtíssimo prazo. Os autores desenvolveram um novo *framework* onde técnicas de reconstrução dinâmica são empregadas para determinar o melhor sistema neural Fuzzy a fim de tratar o problema. Obtiveram um MAPE médio de 0,88% para previsões com frequência de quinze minutos e horizonte de um dia, e um MAPE de 0,89% com essa frequência, mas com um horizonte de duas semanas. Os resultados demonstraram que a abordagem proposta pode tratar a previsão com frequência de quinze minutos com bom desempenho.

Rocco (2008) desenvolveu uma metodologia para previsão do Montate de Uso do Sistema de Transmissão (MUST) nos pontos de conexão das distribuidoras, com prazo de uma semana à frente, com a utilização de duas técnicas de inteligência artificial, a Máquinas de Vetor Suporte para Regressão (SVR) e Redes Neurais Artificiais – Função de Base Radial (RNA-RBF), juntamente com a forma de preparação dos dados e a implementação sobre a base de dados usando estas técnicas. Em uma análise comparativa entre elas concluiu que para a aplicação do

problema real estudado, o uso da SVR é mais adequado visto à facilidade de ajuste, implementação e interpretação dos resultados obtidos, pois as RNA-RBF exigem do analista um conhecimento mais aprofundado da técnica e experiência com a série de dados em questão.

Em outro trabalho, Campos (2010), utiliza como técnica de previsão métodos baseados em redes neurais com algoritmos de retro-propagação (*Back-propagation*) criados a partir de um padrão de desenvolvimento de *software* conhecido como Programação Orientada a Objeto. Para isso utilizou linguagem de programação Java, a qual foi capaz de fornecer os recursos necessários, além de vários outros pontos positivos, como a interdependência de sistemas operacionais, melhor gerenciamento de memória, pouco recurso computacional, dentre outros. Este sistema predictor de cargas elétricas desenvolvido é capaz de realizar previsões de curto prazo (24 a 48 horas). Como inovação apresentou o processo de atribuição dos parâmetros para treinamento da rede neural através de processos exaustivos. A combinação entre a rede neural artificial e técnicas de programação orientada a objeto, visou obter o máximo de exatidão nos resultados da predição de curto prazo. A aplicação desenvolvida nesta pesquisa obteve êxito na maior parte dos testes realizados, sendo que as aplicações para previsão de carga no curto prazo obteve índices de erro inferiores a 1%. Considerou os dias atípicos (feriados) e finais de semana obtendo um excelente desempenho em sua maior parte dos testes, com erro médio inferior a 4%.

Já Altran (2010), desenvolveu uma metodologia para previsão de carga elétrica no curto prazo (24 horas à frente), que chamou de Previsão Multinodal, que pode ser entendida como um sistema inteligente que considera vários pontos da rede elétrica durante a realização da previsão. O sistema desenvolvido conta com o uso de uma rede neural artificial composta por vários módulos, sendo esta do tipo *Perceptron* Multicamadas, cujo treinamento é baseado na retropropagação, com a modificação na função de ativação da rede. A função de ativação usual, função sigmóide, foi substituída por funções de base radial. Este trabalho resultou num sistema capaz de realizar a previsão de cargas em vários pontos do sistema de energia elétrica em muito menos tempo do que realizar a previsão de cada carga, uma a uma, com pouca perda na precisão dos resultados, validando a metodologia desenvolvida como um bom sistema de previsão de cargas multinodal.

Andrade (2010) propôs em seu trabalho, empregar um sistema adaptativo de interferência Fuzzy (ANFIS) para previsão de demanda de energia elétrica no curtíssimo prazo. Diversas configurações de entrada e diferentes arquiteturas foram examinadas para se fazer a previsão de carga elétrica um passo a frente. Utilizou como entradas, séries temporais de demanda de energia elétrica mensuradas em intervalos de cinco minutos ao longo de 7 dias em subestações de distribuição. Concluiu em seu trabalho que os resultados obtidos para previsões de curtíssimo prazo foram equivalentes ou melhores do que aqueles encontrados na literatura nos últimos anos.

2.2 Influências de Variáveis Climáticas

Muitos fatores têm influência sobre a demanda de energia elétrica, e a escolha das variáveis que melhor explicam um dado padrão de carga, auxiliará na adequação do modelo de projeção, de acordo com os objetivos do estudo a ser realizado. As variáveis climáticas: temperatura (°C), umidade relativa do ar (%) e a velocidade do vento (m/s), são as que apresentam grande relevância em termos de seus efeitos sobre a demanda de energia, devido a sua relação com o conforto térmico. Muitos estudos de previsão de demanda de energia elétrica consideram a influência destas variáveis.

Rahman e Hazim (1993) indicaram que a relação entre a demanda de energia e condições climáticas é o parâmetro mais importante para a previsão de demanda no curto prazo.

Karayiannis et al. (2003) compararam o uso de redes neurais *feedforward* e redes neurais de base radial para previsão de demanda de energia elétrica no curto prazo. Ambas as redes neurais foram treinadas com medidas passadas de demanda e de dados meteorológicos.

Já Becalli et al. (2004) combinaram a abordagem supervisionada e não supervisionada das redes neurais para previsão de demanda de energia no curto prazo. Também fizeram uso de informações de clima, como temperatura, umidade relativa do ar e radiação solar.

Em outro estudo Cavallaro (2005) baseou-se no uso de redes neurais artificiais para previsão de demanda de energia elétrica no curto prazo. Ele lembrou que energia elétrica é um produto que não pode ser estocado e que, portanto,

balancear seu fornecimento e demanda é fundamental. Cavallaro (2005) classificou os principais fatores que devem ser considerados no que se refere ao consumo de energia elétrica em: fatores temporais (estações do ano, hora do dia, dia da semana, feriados, etc), fatores econômicos (recessão ou expansão, mudanças no preço da eletricidade, etc), fatores meteorológicos (temperatura, umidade, vento, etc) e eventos ocasionais (eventos esportivos, programas de televisão populares, etc).

Karayiannis et al. (2005) compararam o uso de redes neurais artificiais *feedforward* e redes neurais de base radial para previsão de demanda de energia elétrica no curto prazo. Segundo os autores, a previsão de demanda de energia elétrica depende de vários fatores como temperatura, sazonalidade, ondas de calor, frentes frias e feriados. Assim, eles treinaram as redes neurais com a diferença das medidas de demanda de energia elétrica entre dias consecutivos e com as condições climáticas desses dias, como temperatura e umidade.

Yang et al. (2006) apresentaram um estudo para validar seu modelo que combinava o uso de redes neurais artificiais RBF, com regressão múltipla linear (MLR), com o modelo auto-regressivo integrado de médias móveis (ARIMA) e com o modelo Grey (GM) para previsão de demanda de energia elétrica no curto prazo. Eles utilizaram informações de tempo (hora do dia) e informações climáticas (temperatura, umidade e intensidade solar) para prever o consumo de energia elétrica em um sistema de ar condicionado.

Já Suzuki et al. (2007) criaram modelos baseados em redes neurais artificiais para previsão de temperatura e previsão de demanda de energia elétrica no curto prazo, com diferentes configurações nos dados de entrada.

Romera et al. (2007) afirmaram que, para uma boa previsão de demanda de energia elétrica no curto prazo, é necessário considerar outras informações como temperatura, umidade, hora do dia e dia da semana, enquanto que na previsão de demanda de energia no longo prazo a influência de tais informações está diluída nos valores da série.

Segundo Abdel-Aal (2007) a demanda de energia elétrica muda com o tempo, clima, variáveis sócio-econômicas e mudanças demográficas.

Já Alsayegh et al. (2007) investigaram alguns fatores sócio-econômicos que influenciam no comportamento da demanda de energia elétrica no longo prazo no Kuwait. Os autores descobriram o forte impacto na demanda de energia elétrica motivado pela utilização de equipamentos de ar-condicionado durante o verão e

identificaram a influência do aumento do seu uso no crescimento da demanda de energia elétrica no longo prazo neste país.

No seu trabalho Methaprayoonn et al. (2007) utilizaram como informações de entrada para as redes neurais artificiais, o tempo, temperatura e o histórico de demanda. Também analisaram o impacto que o erro na previsão de temperatura pode causar na previsão da demanda de energia elétrica e, para contornar isso, propuseram o uso de fontes diversas de previsão de temperatura para minimizar o problema.

Tripathi et al. (2008) empregou como entradas para as redes neurais utilizadas em seu trabalho, os indicadores de hora e dia, temperatura e preço, pois os autores asseguraram que estas variáveis são as que mais afetam a previsão de demanda de energia elétrica e existe uma forte correlação entre estas e a demanda.

Bashir e Hawary (2009) afirmaram que existe uma forte correlação entre o comportamento do consumo de eletricidade e variáveis meteorológicas como temperatura, cobertura de nuvens, velocidade do vento e umidade. Por esta razão eles apresentaram dados meteorológicos para a rede neural, combinado com dados históricos de carga, para prever demanda de energia elétrica no curto prazo.

Andrade (2010) em seu trabalho apresenta outros estudos que consideraram as influências variáveis climáticas para a previsão de demanda de energia elétrica, embora não tenha levado em consideração esta influência na sua abordagem de previsão de demanda de energia elétrica no curtíssimo prazo.

Da mesma forma Rocco (2008) afirma que as condições climáticas interferem de maneira decisiva em qualquer modelo de previsão de demanda de energia elétrica, mas, por dificuldades no manuseio e obtenção da base de dados, não faz uso desta informação em seu trabalho, deixando como sugestão para trabalhos futuros, ressaltando que estas informações impactam nos resultados da carga.

Por sua vez, Campos (2010) enfatiza que as condições meteorológicas tem fundamental importância na análise e modelagem das cargas, pois sua análise permite uma maior abstração para que sirvam de entrada para um sistema predictor.

Altran (2010) afirma que a solução do problema de previsão de cargas elétricas via redes neurais artificiais, trata-se de uma solução baseada no treinamento, considerando dados históricos de carga, informações sobre o clima, tempo, entre outros.

É importante salientar que os estudos analisados nesta revisão bibliográfica, que incluíram a influência de variáveis climáticas para a previsão de demanda de energia elétrica, eram todos no longo, médio e curto prazo. Não foi encontrado nenhum estudo de previsão de demanda de energia elétrica no curtíssimo prazo, que considerasse a influência das variáveis climáticas.

2.3 Despacho de Usinas Hidrelétricas

O Brasil, por ser um dos maiores potenciais hidroelétricos do mundo, tem sua matriz energética composta, predominantemente, por esta fonte de energia. A falta de recursos públicos para investimentos em grandes empreendimentos e a preocupação com projetos que tenham impactos ambientais importantes estimularam o surgimento das PCH's como uma alternativa viável para a expansão do fornecimento de energia elétrica.

As centrais elétricas de médio e grande porte, que participam do Sistema Interligado Nacional (SIN), são obrigatoriamente despachadas pelo Operador Nacional do Sistema (ONS), de forma centralizada. As PCH's, por outro lado, são despachadas de forma descentralizada, ou seja, a administração do reservatório e o despacho das máquinas são afetos ao proprietário da planta. Dada a indisponibilidade atual de ferramentas de apoio ao despacho de pequenos aproveitamentos, na maioria das vezes o despacho é feito de forma heurística, sem utilizar recursos científicos e softwares confiáveis (BOURGES, 2009).

Bourges (2009) apresentou um modelo de PCH utilizando a técnica de análise e modelagem denominada Dinâmica de Sistemas, com o apoio do qual se podem fazer simulações de despacho de carga considerando qualquer regime de afluência, levando em conta o efeito de precipitações pluviométricas em sua área de captação. Segundo o autor, este modelo permite a tomada de decisão de despacho em curto prazo, praticamente em tempo real, o que acrescenta melhoria da gestão operacional da unidade, evitando vertimento e parada de máquinas. A modelagem computacional usa o *software* Vensim DSS, da *Ventana Systems, INC*.

Conforme Sperandio et al. (2011) as PCH's são muito importantes economicamente para a maioria das pequenas concessionárias, permissionárias e cooperativas de distribuição de energia elétrica, pois geram boa parte da energia fornecida por estas empresas. Já o restante da energia demandada é adquirido de

outras distribuidoras de maior porte, através de contratos de fornecimento de energia elétrica com valores de demanda contratada, verificados por ponto de conexão, em que são apuradas as demandas máximas horárias não coincidentes ocorridas nos horários de ponta e fora de ponta. A detecção de ultrapassagem do montante contratado gera cobrança de um adicional de ultrapassagem, que onera a empresa contratante. Segundo os autores, o despacho de energia elétrica gerada nas PCH's, na maioria das vezes, é realizado sem a utilização de recursos de automação. Ressaltam que uma PCH típica opera a fio d'água, isto é, o reservatório não permite a regularização do fluxo d'água. Com isso, em ocasiões de estiagem a vazão disponível pode ser menor que a capacidade das turbinas causando ociosidade ou parada das máquinas, em outras situações, as vazões são maiores que a capacidade de engolimento das máquinas, permitindo a passagem da água pelo vertedouro. Por estes motivos se faz necessário controlar o despacho horário da geração, baseando-se na previsão de demanda de energia elétrica no curtíssimo prazo.

Outros trabalhos sobre o assunto são encontrados na literatura, a maioria deles tratando de Centrais ou Usinas Hidrelétricas de médio e grande porte, onde existe reservatório para regular a vazão das turbinas.

Encina (1999) afirma que o problema de despacho de máquinas numa usina hidrelétrica surge quando os estudos do planejamento da operação de curto prazo, a programação e mesmo a supervisão na operação em tempo real, definem a quantidade de energia que a usina deve produzir ao longo do período de planejamento, devido à necessidade de manter o equilíbrio entre a carga e a geração. Em seu trabalho, o autor apresentou um modelo para definir o despacho de máquinas, minimizando perdas, partidas e paradas, em uma grande usina hidrelétrica, utilizando a técnica de Programação Dinâmica.

Já Muller (2010) analisou em seu trabalho, a programação de operação de usinas hidrelétricas, que tem a função de determinar um cronograma de geração que atenda às metas estabelecidas pelo planejamento de curto prazo, atendendo às restrições elétricas. O autor faz um estudo do despacho hidráulico de máquinas e geração de uma usina hidrelétrica individualizada, com a função de determinar na base horária no horizonte de um dia, quais máquinas estarão ativas e determinar os níveis de geração de cada uma delas, respeitando as restrições impostas a cada um dos conjuntos geradores, realizando assim, o despacho ótimo. Para tanto fez uso de

uma técnica híbrida composta de Algoritmo Genético e Programação Não Linear. O autor analisou dois casos distintos. O primeiro para a usina de Itaipu, onde todos os conjuntos geradores possuem a mesma característica e o segundo para a usina de Cachoeira Dourada, MG, que possui conjuntos geradores com características diferentes.

Após a análise da revisão bibliográfica, podemos apontar três características deste trabalho que o diferencia dos já apresentados:

- Considera a influência das variáveis climáticas (temperatura, umidade relativa do ar e velocidade do vento) para a previsão de demanda de energia elétrica no curtíssimo prazo;
- Os valores de entrada de demanda de energia e das variáveis climáticas (temperatura e umidade relativa do ar) para o previsor de demanda de energia elétrica no curtíssimo prazo são obtidos em tempo real, através de um sistema SCADA (*Supervisory Control and Data Acquisition*);
- Os resultados obtidos com o previsor de demanda de energia elétrica no curtíssimo prazo permitem elaborar a programação de operação de uma PCH, de forma a garantir o funcionamento da mesma nos momentos mais críticos, de maior demanda do sistema.

3 MÉTODOS DE PREVISÃO DE DEMANDA

Neste capítulo são apresentados os métodos mais usuais de projeção de demanda de energia elétrica (cargas), visando à melhoria da qualidade no processo de planejamento do sistema elétrico. Maior destaque é dado para os Mapas Auto-Organizáveis ou SOM (*Self-Organizing Map*), por ser o método escolhido para a previsão de demanda neste trabalho.

3.1 Classificação dos métodos segundo o horizonte de projeção

No que diz respeito ao processo de planejamento da operação e expansão dos sistemas elétricos, a projeção de carga pode ser subdividida em: previsões de curtíssimo prazo, curto prazo, médio prazo e longo prazo.

3.1.1 Métodos de Projeção de Médio e Longo Prazo

Uma abordagem mais clássica classifica os métodos em modelos econométricos e de aprendizagem estatísticos (CAMPOS, 2008). Tais modelos combinam teoria econômica e técnicas estatísticas para a previsão de demanda de energia, estimando a relação entre consumo de energia e fatores que influenciam o consumo. As relações são estimadas geralmente utilizando o método dos mínimos quadrados. Neste modelo, o consumo de diferentes setores (residencial, comercial e industrial) é determinado como uma função das condições econômicas e meteorológicas entre outras variáveis, sendo então agregadas às estimativas utilizando dados históricos. Adicionalmente, componentes comportamentais são inseridos nas equações de aproximação. Tais modelos requerem grande quantidade de informações dos consumidores, como equipamentos, formas de uso, dados de economia familiar dentre outros. Sua aplicação costuma ser mais complexa, já que as informações requeridas em muitos casos são de difícil acesso necessitando a realização de elaboradas pesquisas de perfis de consumo dos diversos setores da economia. Por outro lado, metodologias baseadas em regressão linear, séries temporais e inteligência artificial (IA), Redes Neurais Artificiais e Redes Neuro-Fuzzy, vêm mostrando uma boa aplicabilidade para previsão de carga em médio e longo prazo, bem como no caso de estimação de curto prazo (CAMPOS, 2008; MAEDA; LOTUFO; LOPES, 2008).

3.1.2 Métodos de Projeção de Curto e Curtíssimo Prazo

Uma grande quantidade de técnicas de análise estatística e de inteligência artificial vem sendo utilizadas para estimação de cargas no horizonte de curto prazo. Além disso, métodos baseados em regressão linear e séries temporais como os propostos em (BOX; JENKINS; REINSEL, 1994) e em particular os modelos ARMA, ARIMA, ARMAX, e ARIMAX vêm sendo empregados com sucesso para a previsão de demanda de energia (CAMPOS, 2008).

A partir do início dos anos 90 diversos modelos para a previsão de cargas de curto prazo foram desenvolvidos utilizando Redes Neurais Artificiais (RNA) para seus diversos tipos de topologias incluindo Perceptron de Múltiplas Camadas (MLP) (PAPALEXOPOULOS; HAO; PENG, 1994) e Redes Neurais de Base Radial (RBF) (MAEDA; LOTUFO; LOPES, 2008).

Com o intuito de melhorar o desempenho dos modelos baseados em RNA, sistemas híbridos utilizando Redes Neurais e Lógica Fuzzy (Neuro-Fuzzy) foram desenvolvidos, aliando as potencialidades destes métodos (NOSE; LOTUFO; LOPES, 2008; JANG, 1993; COELHO; AGUIRRE, 2003).

Adicionalmente, técnicas baseadas em Máquinas de Vetores de Suporte (SVM), Filtro de Kalman e Sistemas especialistas (SE) podem ser boas alternativas para a previsão de cargas a curto, médio e longo prazo (CAMPOS, 2008). Em Lui et al., (1996) é apresentado um estudo comparativo entre três diferentes técnicas aplicadas à previsão de curtíssimo prazo: Lógica Fuzzy, RNA e modelo de regressão linear.

Independente da previsão que se pretende realizar, alguns fatores possuem influência significativa devendo ser incorporados ao modelo de forma a melhorar a precisão de previsão. Estes fatores podem ser divididos em quatro categorias (NOSE; LOTUFO; LOPES, 2008):

- fatores climáticos como estações do ano, temperatura, umidade, vento;
- fatores cíclicos como dia da semana e mês do ano;
- fatores sazonais como férias e feriados pré-definidos;
- fatores atípicos exemplificados por greves, feriados não programados, entre outros.

A seguir são apresentados os modelos mais usuais utilizados para a previsão de demanda.

3.2 Modelos de séries temporais

Uma série temporal é um conjunto de observações de uma determinada variável, ordenadas segundo o tempo e geralmente em intervalos equidistantes. Métodos baseados em séries temporais têm sido aplicados por décadas nas áreas de economia, processamento digital de sinais, como também na previsão de carga (DIAS, 2008).

Uma metodologia utilizada na modelagem de séries temporais não estacionárias foi proposta em (BOX; JENKINS; REINSEL, 1994). Este método consiste em ajustar modelos auto-regressivos integrados de médias móveis, ARIMA (*Auto Regressive Integrates Moving Average*), uma extensão dos modelos lineares ARMA (modelos auto-regressivos de médias móveis). O fundamento teórico do modelo apresentado em Box, Jenkins e Reinsel (1994) baseia-se na Teoria Geral de Sistemas Lineares que diz que a passagem de um ruído branco por um filtro linear de memória infinita gera um processo estacionário de segunda ordem.

Um processo estocástico é um modelo de série temporal que oferece uma descrição da natureza aleatória do processo que gerou a amostra de observações em estudo. Desta forma, conclui-se que uma série temporal pode ser interpretada como uma parte da trajetória ou de uma realização parcial de um processo estocástico. Em relação à estacionariedade, um processo é dito estacionário se o processo estocástico subjacente que gerou a série for invariante em relação ao tempo. Porém, na prática a maioria dos processos são não estacionários, ou seja, variam em relação ao tempo. Por exemplo, o consumo atual de energia hoje é muito maior do que o de 30 anos atrás. Isso indica que o processo que gerou a série de 30 anos atrás é diferente do processo gerador atual.

Muitas das séries temporais não estacionárias têm a propriedade de se tornarem estacionárias após a diferenciação sucessiva, sendo chamada de não estacionária homogênea. O número de vezes que a série original deve ser diferenciada antes de resultar numa série estacionária é denominado ordem de homogeneidade. Nesse sentido, em Box, Jenkins e Reinsel (1994) propõe-se que um processo estocástico estacionário, por possuir média, variância e autocorrelação invariante em relação ao tempo, pode ser otimamente representado por um modelo auto-regressivo (AR), de médias móveis (MA) ou uma combinação dos dois (ARMA), obtido por intermédio da passagem de uma série ruído branco por um filtro linear, o

que significa que a série resultante poderá ser vista como uma combinação linear da série original. O processo resultante dessa passagem, considerando-se este filtro como estável, também será estacionário.

Os processos encontrados na prática, além de raramente serem estacionários, apresentam muitas vezes componentes sazonais. Assim, em Box, Jenkins e Reinsel (1994) formulam-se os modelos para séries temporais com componentes sazonais dando origem aos modelos ARIMA sazonal (SARIMA) (DIAS, 2008). O passo inicial desta metodologia é verificar se a série em estudo é estacionária e, caso não seja, determinar o possível grau de homogeneidade. A opção pela modelagem autoprojativa se justifica por uma análise exploratória dos dados de consumo, ou seja, se procura verificar determinados padrões no consumo de energia elétrica no Brasil através da análise da estrutura de correlação destes dados no tempo. Isto pode ser feito através da análise da função de autocorrelação.

3.3 Modelos de regressão dinâmica

Trabalhos recentes têm apresentado modelos para previsão de demanda de energia elétrica que utilizam uma formulação causal, conhecida como Regressão Dinâmica (RD). No modelo causal, basicamente, as previsões de uma determinada série levam em consideração as informações do passado da mesma e também de outras séries de variáveis que possam influenciar a principal. Estas variáveis são denominadas explicativas, exógenas ou causais. O uso da RD pode ser explicado pelo fato de que para a obtenção das previsões do mercado cativo de energia elétrica de uma distribuidora, para um período relativamente longo, seja necessária a inserção de eventos diretamente ou indiretamente relacionados ao comportamento deste mercado para aumentar a precisão do modelo (SILVA, 2008). Cada uma dessas premissas vinculadas ao consumo de energia pode ser do campo econômico e/ou demográfico, por exemplo. Dispondo de tais premissas como parâmetros iniciais, busca-se identificar modelos econométricos capazes de caracterizar a relação existente entre a demanda por energia elétrica por classe de consumo na área de concessão, com as variáveis explicativas analisadas.

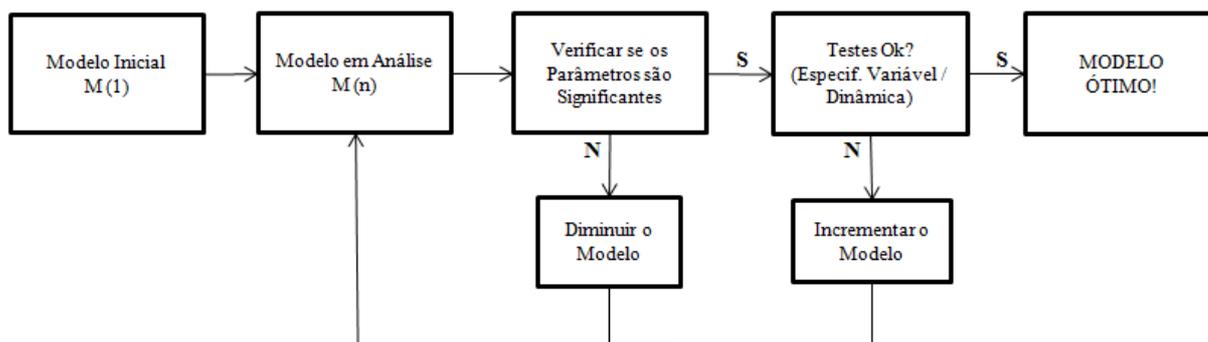
Nos modelos de regressão linear, comumente estudados na literatura, supõe-se que os erros gerados pelo modelo possuem algumas características como: média zero, variância constante, distribuição normal e independência, implicando na

inexistência de correlação serial. Na modelagem de séries econômicas através da regressão linear, há uma tendência de resíduos se agruparem em blocos de resíduos com o mesmo sinal. Ao modelar estas séries, os resíduos têm uma tendência de possuir correlações positivas, e os erros positivos tendem a ser acompanhados por outros positivos. É identificado um comportamento similar para resíduos negativos. Ao se tentar modelar uma série temporal através de um modelo de regressão, a hipótese de independência dos ruídos não é realista, e os resultados e testes usados nos modelos de regressão não são válidos (DIAS, 2008).

Os modelos de regressão dinâmica além de contemplarem a evolução no tempo da variável de interesse, também consideram o efeito de variáveis explicativas, considerando-se assim uma expansão dos modelos de série temporais. O termo “regressão dinâmica” não indica que os parâmetros do modelo evoluem no tempo, mas sim um modelo de regressão no qual é incluída a estrutura de dependência de uma série temporal. As previsões determinadas por um modelo de regressão dinâmica dependem, além dos dados passados da série, também dos valores previstos para as variáveis explicativas. Com isto, é imprescindível prover aos modelos os valores futuros das variáveis explicativas, para então se obter as previsões.

A estimação dos parâmetros de um modelo de RD é feita através de mínimos quadrados ordinários, como nos modelos de regressão usuais. No entanto, a estimação para um modelo de RD é mais complexa e envolve um processo iterativo com vários estágios. A Figura 1, obtida de Silva (2008), apresenta um fluxograma para construção de um modelo de regressão dinâmica:

Figura 1 - Fluxograma para a construção de um modelo de Regressão Dinâmica



Fonte: Silva, 2008.

Os modelos de RD possuem as seguintes equações:

$$Y_t = \beta_0 x_t + \beta_1 x_{t-1} + \dots + \beta_k x_{t-k} + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_m Y_{t-m} + \varepsilon_t \quad (1)$$

De acordo com a Equação 1, a variável endógena Y_t no modelo de RD é explicada pelas suas defasagens e pela variável causal (exógena) x_t e suas defasagens. Visando uma simplificação no modelo, consideram-se as defasagens da variável exógena como uma variável exógena, omitindo-se os termos $x_{t-1} + x_{t-2} + \dots + x_{t-k}$. Portanto, a Equação 1 pode ser reescrita como:

$$\varphi(B) Y_t = \beta x_t + \varepsilon_t \quad (2)$$

onde, Y_t é a variável dependente (exógena) no instante t , β é o vetor de coeficientes das variáveis causais que será estimado por mínimos quadrados, X_t é o vetor de variáveis causais (exógenas) incluindo suas possíveis defasagens e ε_t representa o ruído aleatório associado ao modelo, onde supõe-se que estes são independentes e identicamente distribuídos.

Com base na Equação 1 tem-se que $\varphi(B)$ é o polinômio auto-regressivo de ordem p e operador de defasagem B , definido como sendo:

$$\varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_m B^m \quad (3)$$

3.3.1 Construção dos modelos de RD

Os modelos econométricos geralmente possuem uma estrutura conhecida baseada na teoria econômica. No entanto, este é raramente o caso dos modelos de séries de tempo, em que o modelo é construído a partir de dados. Usualmente emprega-se na construção de um modelo de RD a estratégia *bottom-up*, onde se parte de um modelo simples, incrementando-o até que se obtenha um modelo apropriado (DIAS, 2008). Ainda, não é suficiente que os parâmetros estimados sejam significantes. É preciso que o modelo estimado seja consistente com a teoria econômica. Por exemplo, um coeficiente positivo da variável explicativa preço de certo produto, em um modelo de previsão de consumo deste, indica que um

aumento no preço levaria a um aumento no consumo do mesmo, o que contradiz a teoria econômica.

Para se obter as previsões (Y_{t+1} , Y_{t+2} , ..., Y_{t+k}) da variável de interesse (Y_t) é necessário fornecer ao modelo os valores futuros das variáveis causais x_t . As previsões destas variáveis devem ser adequadas para que o modelo de RD não gere valores futuros para Y_t inadequados. Por outro lado, tal condição possibilita a criação de cenários para as variáveis causais, possibilitando analisar os possíveis valores futuros da variável de interesse em diversas condições.

Outro tipo de variável que também pode ser utilizada nos modelos de RD é a variável *dummy* (ou variável de intervenção). A função deste procedimento é considerar ocasiões atípicas no modelo como quebras estruturais na série, por exemplo, o aumento das vendas de brinquedo no Natal, onde é razoável incluir *dummies* para o mês de dezembro. Ainda, ao invés de supor que a série será previamente dessazonalizada, os modelos de RD incorporam ainda diretamente a sazonalidade da série ao modelo, através de defasagens na variável dependente ou ainda nos erros estruturados ou via *dummies* sazonais.

3.3.2 Testes usados nos modelos de RD

Para responder às perguntas presentes no fluxograma da Figura 1 acerca da significância dos parâmetros e diagnósticos, até que se chegue ao modelo selecionado, são usados vários testes estatísticos. Estes testes são aplicados a diversos estágios da série e possuem diversos objetivos, como: definir a especificação do modelo explicativo, encontrar a dinâmica do modelo (definir a inclusão ou não de variáveis defasadas) e verificar o ajuste do modelo.

Pode-se encontrar na literatura vários testes que são utilizados na prática. O processo de construção de um modelo de RD deve considerar diversos diagnósticos com o objetivo de verificar se o modelo atual é apropriado. Em particular, deve-se sempre examinar o gráfico das autocorrelações dos resíduos. Se estas são significantes para alguns *lags*, este fato pode indicar que alguma característica da variável dependente não foi capturada pelo modelo estimado. Por exemplo, no caso de dados mensais, se a autocorrelação dos resíduos é significativa no *lag* 12, a observação situada num período genérico $t-12$ meses é relevante para explicar a

observação no período t e espera-se que sua inclusão no modelo resulte num decréscimo dos erros de previsão do modelo.

3.3.3 Exemplo de aplicação

O *software Forecast Pro for Windows* (FPW) pode ser utilizado para gerar os modelos de previsão. No trabalho apresentado em Silva (2008), cujo objetivo era prever o consumo de todo o mercado cativo atendido por uma distribuidora de energia elétrica para um horizonte pré-definido, o FPW foi utilizado. Como a finalidade é prever o consumo cativo total, foram desenvolvidos modelos para todas as classes, inclusive as de menor consumo. As séries históricas de consumo de energia utilizadas compreenderam o período entre janeiro de 1990 e dezembro de 2007, e a previsão realizada considerou um horizonte de 5 anos (de janeiro de 2008 a dezembro de 2012). Considerando que algumas classes têm um peso mais significativo no consumo total da distribuidora analisada, fez-se ainda uma abertura em níveis de tensão: Alta Tensão (AT), Média Tensão (MT) e Baixa Tensão (BT), visando uma maior precisão no estudo de planejamento do consumo de energia elétrica. Este detalhe pode possibilitar a identificação de comportamentos específicos para consumidores que operam em níveis diferentes de tensão, mas pertencem a uma mesma classe.

Nos modelos de RD, a variável dependente é explicada por seus valores defasados e pelos valores atuais, e passados de variáveis causais ou exógenas, e devem ser usados quando a estrutura de correlação da série dependente indicar que não se pode supor a independência dos erros. Estas variáveis causais ajudam a explicar a variável dependente, no caso o consumo de energia elétrica. As variáveis causais refletem as variáveis Proxy, isto é, fatores que influenciam no comportamento da variável principal. Em Silva (2008) foram consideradas variáveis explicativas referentes a:

- níveis de preços na economia, como a variação do índice nacional de preços ao consumidor, índice de preços de eletrodomésticos e equipamentos, índice de preços de condicionadores de ar, índice de preços de refrigeradores;
- características do faturamento da distribuidora estudada, como número de contas faturadas da classe residencial MT, tarifa média residencial MT e BT, entre outras;

- estrutura de renda dos consumidores, como rendimento médio real do pessoal ocupado, participação dos gastos com energia elétrica, entre outras;
- atividade econômica, como taxa de desemprego, índice de emprego na indústria, entre outros;
- temperatura;
- calendário (número de dias, número de sábados e domingos, número de dias úteis).

Nesta consideração cada variável explicativa é relacionada a uma ou mais classes de consumo. Além das variáveis explicativas listadas acima, também foram testadas e utilizadas, para todas as classes de consumo, variáveis de intervenção (*dummies*), com objetivo de captar alguns eventos específicos como a intervenção para racionamento (maio de 2001 a fevereiro de 2002) e a intervenção para mudança de nível pós-acionamento (março de 2002 a dezembro de 2007). A cada série de consumo de uma determinada classe foram agregadas as séries das respectivas variáveis explicativas apresentadas acima. No entanto, o período de algumas séries de variáveis explicativas não coincide com o período disponível para a série de consumo. Logo, foram realizados testes considerando inícios diferentes para a série de consumo e assim foi possível utilizar as variáveis de acordo com o início de seus dados.

O programa FPW é, então, utilizado para desenvolver os modelos de previsão, e o modelo final pode ser definido pela análise das estatísticas de desempenho, sendo elas:

- *Mean Absolute Percentual Error* (MAPE): calculado pela diferença entre valores estimados e reais. Equivale às previsões um passo à frente (no caso, para o mês seguinte);
- R^2 ajustado (coeficiente de explicação): indica o quanto da variação total dos dados (série dependente, no caso a energia faturada) é explicada pelo modelo. É calculado através da comparação do erro do modelo com a variação dos dados da série dependente em torno de sua média; e
- *Geometric Mean Relative Absolute Error* (GMRAE): compara o erro do modelo em questão com o erro do modelo ingênuo (aquele que usa como previsão o último dado disponível). É desejável que seja menor ou igual a um.

3.4 Redes neurais artificiais

As Redes Neurais Artificiais (RNAs) são também conhecidas como conexionismo ou sistema de processamento paralelo e distribuído. Este modo de computação não algorítmica é caracterizado por sistemas que se assemelham à estrutura do cérebro humano (BRAGA; CARVALHO; LUDEMIR, 2000). O cérebro humano contém algo em torno de 10^{11} neurônios, sendo que cada um deles processa e se comunica com milhares de outros de modo contínuo e paralelo. O cérebro humano, entre outras funções, é responsável pelo pensamento, percepção e cognição. Possui também uma rede de nodos que tem a capacidade de reconhecer padrões e relacioná-los, usar e armazenar conhecimento por experiência e interpretar observações.

Apesar de todos os estudos realizados, ainda não se sabe ao certo a forma como as funções cerebrais são realizadas. O que se tem, até o momento, são modelos (redes neurais artificiais) baseados na estrutura fisiológica básica destas redes de nodos naturais. No entanto, do ponto de vista físico, as redes artificiais diferem das redes biológicas. Destacam-se, contudo, as similaridades entre dois tipos de sistemas, buscando-se entender melhor o sistema nervoso, com ideias e inspirações para a pesquisa em neurocomputação. Como características comuns tem-se que os dois tipos de sistemas são baseados em unidades de processamento paralelos e distribuídos, se comunicam por meio de conexões sinápticas, possuem detectores e características, redundância e modularização das conexões. Estas características comuns permitem as RNAs reproduzir com fidelidade várias funções somente encontradas nos seres humanos. O futuro da neurocomputação se beneficiará, cada vez mais, do desenvolvimento de modelos que tenham apelo biológico, pois outras estruturas encontradas nos sistemas biológicos podem inspirar o desenvolvimento de novas arquiteturas para modelos de RNAs (BRAGA; CARVALHO; LUDEMIR, 2000).

As RNAs são caracterizadas por sistemas paralelos distribuídos, compostos por unidades de processamento simples (nodos) que calculam determinadas funções matemáticas (em geral, não lineares). Estas unidades são dispostas em uma ou várias camadas interligadas por conexões em geral uni-direcionais, as quais estão associadas pesos, que armazenam o conhecimento representado no modelo, ponderando cada entrada recebida de cada neurônio da rede. A solução de

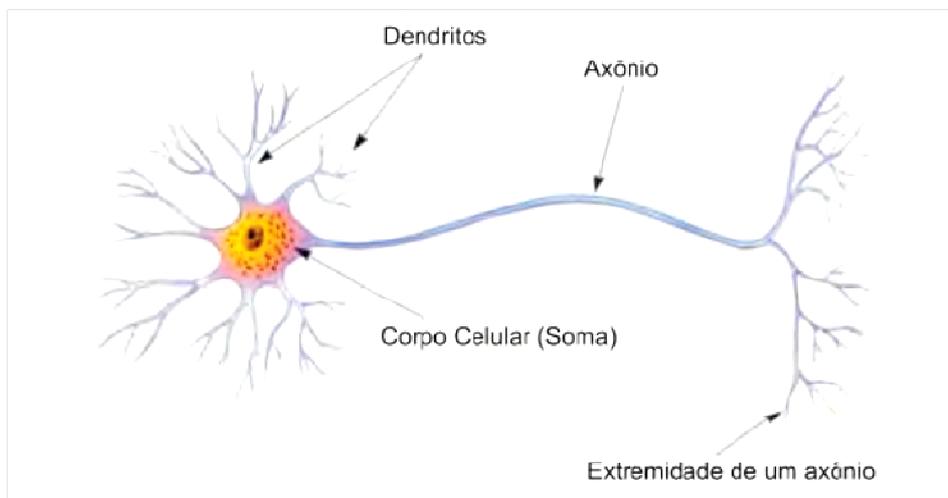
problemas por meio de RNAs é atrativa, uma vez que é inerente à sua arquitetura e são representadas internamente pelo paralelismo natural, possibilitando um desempenho superior ao dos modelos convencionais. Esta característica se deve ao fato de que uma RNA é capaz de realizar um processo de aprendizagem quando um conjunto de exemplos (dados de uma amostra) lhe é apresentado, e por sua vez, extrai automaticamente as características necessárias para representar a informação fornecida. Estas características são armazenadas sob forma de pesos que posteriormente são utilizados para gerar respostas para o problema.

Com o avanço computacional dos microprocessadores tem ocorrido um aumento significativo nas aplicações com as redes neurais, principalmente em se tratando de não linearidades.

3.4.1 Neurônio biológico

Para melhor compreensão dos neurônios artificiais, cita-se que sua origem foi iniciada por meio de modelagem de um neurônio biológico, o qual é dividido em três seções: o corpo da célula, os dendritos e o axônio, cada um com funções específicas, porém complementares. Na Figura 2 são apresentadas as três seções de um neurônio biológico, sendo que os dendritos têm por função receber as informações (impulsos nervosos) oriundas de outros neurônios e conduzi-lás até o corpo celular, onde é processada, gerando novos impulsos, que são transmitidos a outros neurônios passando através do axônio até os dendritos dos neurônios seguintes. O ponto de contato entre um axônio e um dendrito é chamado sinapse. É através das sinapses que os nodos se unem funcionalmente, formando redes neurais. As sinapses funcionam como válvulas e são capazes de controlar a transmissão de impulsos (fluxo de informação) entre os nodos na rede neural. O efeito das sinapses é variável, o que fornece ao neurônio sua capacidade de adaptação. Os sinais provindos dos neurônios pré-sinápticos são transmitidos para o corpo do neurônio pós-sináptico, onde são comparados com outros sinais recebidos pelo mesmo (BRAGA; CARVALHO; LUDEMIR, 2000).

Figura 2 - Modelo de um neurônio biológico

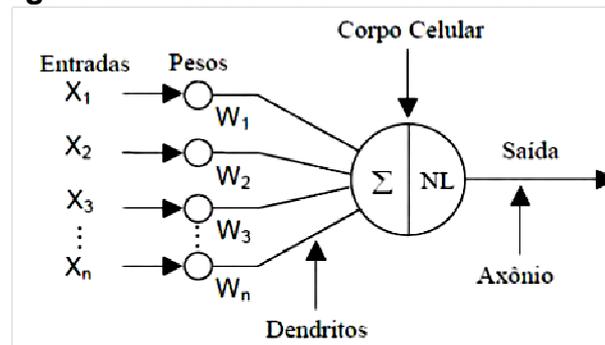


Fonte: Campos, 2010.

3.4.2 Neurônio artificial

Em 1943, foi proposto por McCulloch e Pitts um modelo inicial de um neurônio artificial (modelo MCP), que consiste em uma simplificação do que se sabia, até então, a respeito do neurônio biológico. A descrição matemática resultou em n terminais de entrada ($x_1, x_2, x_3, \dots, x_n$) que representam os dendritos, e apenas um terminal de saída y , representando o axônio. Para emular o comportamento das sinapses, os terminais de entrada do neurônio têm pesos acoplados $w_1, w_2, w_3, \dots, w_n$, cujos valores podem ser positivos ou negativos, dependendo das sinapses correspondentes serem inibitórias ou excitatórias. Os pesos determinam em que grau o neurônio deve considerar sinais de disparo que ocorrem naquela conexão (BRAGA; CARVALHO; LUDEMIR, 2000). Este modelo está ilustrado na Figura 3.

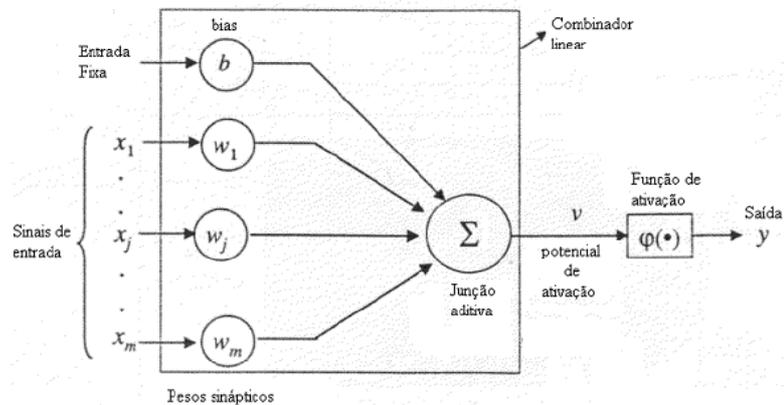
Figura 3 - Modelo de um neurônio artificial.



Fonte: Campos, 2010.

Um neurônio é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural (HAYKIN, 2001). Com o tempo, o modelo inicial de neurônio, proposto por McCulloch e Pitts, foi aperfeiçoado, passando a ser apresentado como o diagrama da Figura 4, que se constitui como a base para o projeto de RNA.

Figura 4 – Modelo de um neurônio (aperfeiçoado).



Fonte: Adaptado de Haykin, 2001.

O modelo de neurônio mostrado na Figura 4 é associado a uma estrutura matricial, com entradas $x_1, x_2, x_3, \dots, x_n$, e uma só saída y . Cada entrada tem seu peso associado $w_1, w_2, w_3, \dots, w_n$, que pondera quantitativamente cada entrada em relação a saída. O produto da entrada pelos pesos determina a primeira operação matemática de um neurônio artificial, juntamente com um limiar de ativação do neurônio b (bias). As bias têm o efeito de aumentar ou diminuir a entrada líquida da função de ativação. O resultado dessa soma (v) é a variável independente de uma função de ativação $\varphi(\bullet)$, que faz a correspondência do somatório anterior com a saída y , atuando de modo a limitar a amplitude do sinal de saída. A seguir são apresentadas as equações para descrever um neurônio artificial:

$$u = \sum_{j=1}^m x_j \cdot w_j \quad (4)$$

$$v = (u + b) \quad (5)$$

$$y = \varphi(v) \quad (6)$$

onde, m é o número de entradas do neurônio, w_j representa o peso atribuído à j , b é o limiar de ativação do neurônio, v é a variável de entrada da função de ativação do neurônio e y é a saída do neurônio.

3.4.3 Arquitetura das RNAs

A arquitetura de uma RNA é um parâmetro importante de sua concepção, já que a mesma é restringida pelo problema que irá resolver. A estrutura de uma rede neural é basicamente composta por três camadas. A primeira delas é a camada de entrada, responsável apenas pela recepção do vetor variáveis, com as informações a serem processadas pelo restante da rede. A segunda é a camada intermediária ou oculta, que pode ser única ou com várias subcamadas, em cascata, a qual é responsável pelo processamento da informação recebida pela camada de entrada. Por último a camada de saída, responsável pela fase final do processamento e apresentação dos resultados (HAYKIN, 2001). A literatura menciona três classes de arquitetura de redes neurais: redes alimentadas adiante com camada única, redes alimentadas diretamente com múltiplas camadas e redes recorrentes (BRAGA; CARVALHO; LUDEMIR, 2000).

Uma rede neural artificial é constituída de unidades simples: o neurônio artificial (Figura 3), matematicamente definido pelas Equações 4 a 6 e um algoritmo de treinamento. O cascadeamento entre um conjunto de neurônios – ou elementos de processamento – e o paralelismo formam a topologia da rede, que através do grande número de conexões, e de seus respectivos pesos, entre estes elementos de processamento, transforma a rede neural em uma poderosa ferramenta para a resolução de uma inumerável quantidade de problemas. Os problemas aos quais as RNAs são aplicáveis consistem basicamente em situações onde existam dados, experimentais ou não, que são apresentados à rede em uma etapa denominada de “treinamento”. Nesta etapa, os pesos sinápticos são ajustados com intuito de que alguma tarefa seja realizada. Além da capacidade de aprendizado a partir de exemplos, as redes possuem a capacidade de generalização, que consiste na habilidade da mesma em apresentar soluções para dados distintos (dados de “validação”), diferentes dos dados apresentados na etapa de treinamento. As principais características das RNAs são:

- aprendizado a partir de exemplos;

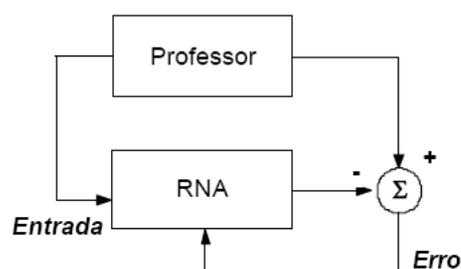
- adaptabilidade;
- capacidade de generalização;
- tolerância a falhas; e
- rápida implementação.

3.4.4 Aprendizagem de RNAs

No aprendizado conexionista não se procura obter regras como na abordagem simbólica da inteligência artificial, mas sim determinar a intensidade de conexões entre os neurônios. A partir de um conjunto de procedimentos bem definidos para adaptar os parâmetros de uma RNA, como seus pesos (w_i) e seu limiar de ativação (b), para que a mesma possa aprender uma determinada função (algoritmo de aprendizado) a rede extrai informações de padrões de dados apresentados para ela, criando uma representação própria para o problema. Trata-se de um processo iterativo de ajuste de parâmetros da rede, no qual os pesos das conexões entre as unidades de processamento guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente no qual está operando (BRAGA; CARVALHO; LUDEMIR, 2000).

Um dos diversos métodos de aprendizagem de uma RNA é o Aprendizado Supervisionado. Neste método, o agente supervisor é metaforicamente chamado de professor ou retropropagação do erro (*backpropagation*), sendo o algoritmo mais utilizado para o ajuste dos pesos da rede neural por meio da minimização do erro na camada de saída da rede. O processo se repete até que se atinja o ponto ótimo, que é determinado pelo menor erro, como mostra a Figura 5:

Figura 5 - Aprendizado supervisionado de uma RNA.



Fonte: Silva, 2011.

O algoritmo de aprendizagem é definido por um conjunto de regras bem definidas para a solução de um problema de aprendizagem. Não há um algoritmo de aprendizagem único para o projeto de redes neurais, posto que os mesmos diferem na maneira pela qual o ajuste dos pesos é feito. O que se tem, de fato, é um conjunto de ferramentas, representado por uma variedade de algoritmos, cada qual oferecendo vantagens específicas, diferindo entre si na forma como o ajuste de um peso sináptico de um neurônio é formulado. Considera-se, também, a forma pela qual uma rede neural constituída de um conjunto de neurônios interligados se relaciona com o seu ambiente.

3.4.5 Algoritmo de treinamento

O algoritmo de treinamento de retropropagação do erro, mais conhecido como *backpropagation*, é o algoritmo mais popular para o treinamento de RNAs multicamadas. Basicamente, o algoritmo consiste de dois passos: a propagação e a retropropagação. No primeiro passo, um vetor de entradas é aplicado à camada de entrada e o seu efeito se propaga pela rede produzindo um conjunto de saídas. A resposta obtida pela rede é subtraída da resposta desejada para produzir um sinal de erro. O segundo passo consiste em propagar esse sinal de erro na direção contrária às conexões sinápticas, ajustando-as de forma a aproximar as saídas da rede das saídas desejadas.

3.4.6 Perceptron multicamadas (MLP)

A Perceptron Multicamada é mais conhecida por sua sigla MLP, do inglês *Multilayer Perceptron*. A característica marcante de uma rede MLP é que ela pode ter várias camadas ocultas. A MLP basicamente consiste de uma camada de nós, (fontes de entrada), uma ou mais camadas de nós processadores ou computacionais (neurônios) ocultos e uma camada de saída também composta por nós computacionais. A camada formada por neurônios ocultos (camada oculta) recebe este nome porque não há acesso da entrada e nem da saída sobre esta camada. As redes MLP possuem capacidade de resolver problemas não lineares. Em uma rede MLP, basicamente, tem-se como parâmetros de escolha: número de

neurônios na camada de entrada, número de camadas escondidas e o número de neurônios nestas camadas e número de neurônio na camada de saída.

Embora a literatura cite alguns algoritmos para realizar a escolha destes parâmetros, não existe uma solução geral que atenda a todos os casos. Dessa forma, essa escolha torna-se parte do problema e a solução varia de acordo com cada caso e com a complexidade de cada processo.

3.4.7 Controle de generalização

Um ponto importante a ser observado no treinamento de redes MLP é o controle de generalização. Sabe-se que quando uma rede apresenta complexidade inferior à complexidade do problema ela não conseguirá se ajustar aos dados e irá apresentar erros elevados, tanto no treinamento, quanto na validação. Essa é uma questão que deve ser observada no momento do treinamento da rede. Uma forma de se tratar este problema é o uso do algoritmo chamado *Early Stopping* ou Parada Precoce (BRAGA; CARVALHO; LUDEMIR, 2000).

O processo de treinamento de uma RNA pode ser dividido em duas etapas distintas. Na primeira o erro de treinamento e o erro de validação diminuem, mostrando que a rede está apreendendo as principais características dos dados apresentados. Na segunda etapa, o erro de treinamento continua a diminuir enquanto que o erro de validação tende a aumentar. Nesse ponto a rede passa e se especializar nos dados do treinamento, acarretando a perda da capacidade de generalização e no conseqüente aumento do erro de validação. O algoritmo sugere que o treinamento se encerre quando o erro de validação comece a aumentar.

3.4.8 Procedimento para a RNA

Para os procedimentos da RNA devem considerados:

- escolha das entradas do modelo;
- escolha do número de neurônios na camada escondida;
- escolha das saídas;
- porcentagem de dados para treinamento; e
- validação.

A escolha do número de neurônios na camada de entrada, no problema de modelagem de séries temporais, trata-se basicamente da escolha dos atrasos utilizados como entradas no modelo. O neurônio da camada de saída corresponde no problema de modelagem de séries temporais, ao horizonte de previsão. Existem duas formas de se construir um modelo de previsão. A primeira é a previsão de um passo à frente, em que apenas um neurônio é utilizado na camada de saída. A segunda forma é utilizada quando se deseja ter como saída a previsão em um horizonte maior do que a amostragem da série. Por exemplo, deseja-se obter a previsão para 6 meses à frente, para uma série de amostragem mensal. O que se pode fazer é utilizar as previsões de um passo à frente e realimentá-las no modelo para obter as previsões no horizonte maior, ou ainda utilizar mais neurônios na camada de saída obtendo a saída diretamente sem a necessidade de realimentar previsões. O neurônio da camada escondida normalmente é obtido por tentativas. Na literatura, até onde foi pesquisado, não se encontrou uma metodologia para determinar o número de neurônios da camada escondida.

Uma questão importante a ser definida é a composição dos dados para treinamento e validação, isto é, quais os dados que serão usados para treinar os modelos, e quais serão utilizados para validá-los. A literatura sugere que pelo menos 20% da base de dados sejam separadas para validar os modelos obtidos na fase de treinamento (BRAGA; CARVALHO; LUDEMIR, 2000).

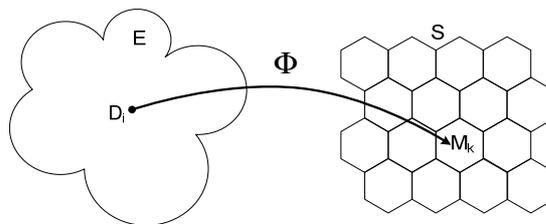
3.4.9 Mapas Auto-Organizáveis – SOM (Self-Organizing Map)

Os Mapas Auto-Organizáveis ou *Self-Organizing Map* (SOM) foram desenvolvidos pelo Professor Teuvo Kohonen, pesquisador da Universidade de Helsinque, Finlândia, a partir de 1982. É um modelo de rede neural desenvolvido para reconhecimento de padrões (KOHONEN, 2001). Caracteriza-se por ser um modelo de aprendizado não supervisionado, ou seja, não se faz necessário apresentar a entrada e a saída ideal para que a rede aprenda como se adaptar a essa saída. Os modelos são atualizados pela informação recebida por cada um. Outra característica interessante no modelo de Kohonen é que os neurônios são auto-organizáveis, como diz o próprio nome. Com o passar do tempo a rede vai criando grupos de neurônios especializados em certas entradas.

O algoritmo SOM é definido como uma transformação Φ não-linear, que mapeia um espaço de entrada E contínuo, cuja topologia é definida pela relação métrica dos vetores de dados $D \in E$, para um espaço de saída S discreto, cuja topologia é definida por um conjunto de modelos M dispostos em uma grade bidimensional, como mostra a Figura 6 (HAYKIN, 2001).

“O principal objetivo do Mapa Auto-Organizável é transformar um padrão de sinal incidente de dimensão arbitrária em um mapa discreto uni- ou bi-dimensional e realizar esta transformação adaptativamente de uma maneira topologicamente ordenada.” (HAYKIN, 2001).

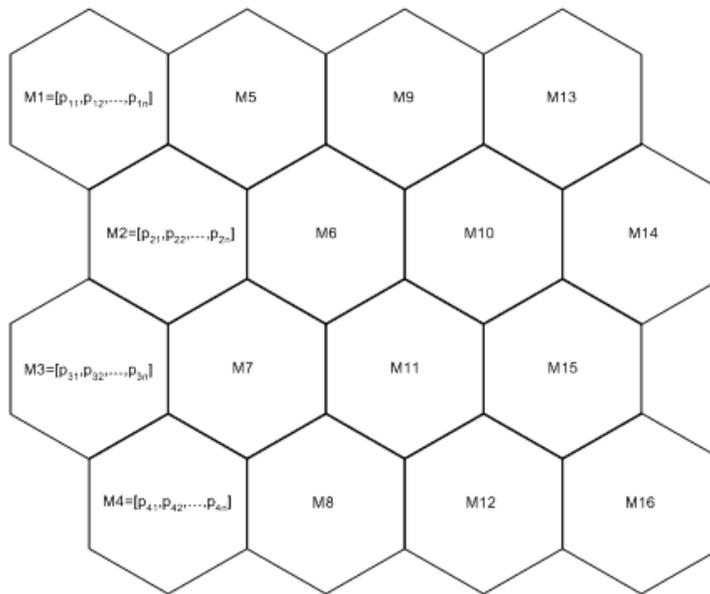
Figura 6 - Uma transformação $\Phi: E \rightarrow S$ em um mapa 4x4 com conexões hexagonais.



Fonte: Haykin, 2001.

Conforme Sperandio (2004), o padrão de sinal incidente é um dado de entrada, composto por um vetor de dimensão arbitrária “n”, que são as variáveis de entrada utilizadas. O mapa é formado por neurônios, que contem modelos que também são vetores de dimensão “n” (pesos sinápticos). Os neurônios são conectados entre si como uma rede (Figura 7). Cada neurônio tem conexões com todos os elementos do vetor de entrada.

Figura 7 - Mapa ou rede hexagonal com 16 modelos (4x4).



Fonte: Sperandio, 2004.

O processo de ordenação consiste em encontrar o neurônio vencedor, ou seja, aquele que melhor atende ao estímulo proporcionado pelo vetor de entrada. As ligações servem para ajustar modelos de neurônios próximos ao vencedor (neurônios vizinhos) ao padrão de entrada. Desta forma, ao final de várias iterações, o mapa apresenta os dados associados aos seus neurônios, de forma que padrões similares encontram-se em neurônios contíguos (SPERANDIO, 2004).

O processo de ordenação acontece em três etapas: inicialização, treinamento e visualização.

3.4.9.1 Inicialização

Na inicialização é feita a configuração inicial dos modelos. Esta configuração pode ser montada de duas formas:

- Aleatória: Quando os pesos sinápticos de cada modelo são distribuídos por sorteio. Essa é uma maneira de se comprovar a auto-organização do mapa, mas exige muito mais iterações e, portanto, maior processamento.
- Linear: Quando se tem a intenção de se impor alguma ordem já na criação do mapa, mesmo que alguns modelos fiquem fora da distribuição de

probabilidade de dados. O mapa já começa de certa forma, organizado, conseguindo atingir uma configuração estável com muito menos iterações do que em uma inicialização aleatória.

3.4.9.2 Treinamento

Após iniciado o mapa, passa-se para a fase de treinamento, quando são ajustados os pesos sinápticos aos padrões de entrada para formar o espaço de saída discreto. Esta fase está dividida em processo competitivo, cooperativo e adaptativo.

No processo competitivo, para cada padrão de entrada, os modelos (neurônios) do mapa calculam seus respectivos valores de base para competição entre os neurônios. O neurônio particular com maior valor da função discriminante é declarado vencedor.

No processo cooperativo é realizado o reajuste dos pesos sinápticos de uma região (vizinhança topológica de neurônios excitados) a cerca do neurônio vencedor e não simplesmente o peso sináptico do neurônio vencedor. Estabelece-se, assim, a base para a cooperação entre os neurônios vizinhos.

O último mecanismo de treinamento é o processo adaptativo, que permite que os neurônios excitados aumentem seus valores individuais da função discriminante em relação ao padrão de entrada, através de ajustes adequados, aplicados a seus pesos sinápticos. Os ajustes feitos são tais que a resposta do neurônio vencedor à aplicação subsequente de um padrão de entrada similar é melhorada.

3.4.9.3 Visualização

A interpretação do resultado final do algoritmo de auto-organização é muito importante para a correta obtenção dos resultados, e para extrair o máximo de informações que esse método proporciona.

O mapa é um espaço de saída discreto de uma transformação injetora. Após o processo de organização, cada elemento da base de dados utilizada para treinar o mapa será representado por um, e apenas um, dos neurônios da rede. Porém, cada neurônio poderá representar qualquer quantidade de elementos, inclusive nenhum. Como o mapa representa a densidade de probabilidade de ocorrência dos

elementos da base de dados de uma forma ordenada, quando existir uma distância muito grande entre grupos de elementos, ou elementos discrepantes isolados (*outliers*), se o mapa for relativamente grande, durante o processo de organização existirão alguns modelos que ficarão adaptados ao espaço que separa estes grupos, e, portanto não conseguirão vencer nenhum dado de entrada (SPERANDIO, 2004).

Ao final de várias iterações o mapa apresenta os dados associados aos seus neurônios, de forma que padrões similares encontram-se em neurônios contíguos, tendo uma organização topológica. Deste modo é possível se extrair relações abstratas entre as variáveis do vetor de dados através de sua posição nos mapas componentes, que por meio de uma escala de cores mostram a quantidade de uma variável específica em cada neurônio do mapa (SPERANDIO et. al., 2011).

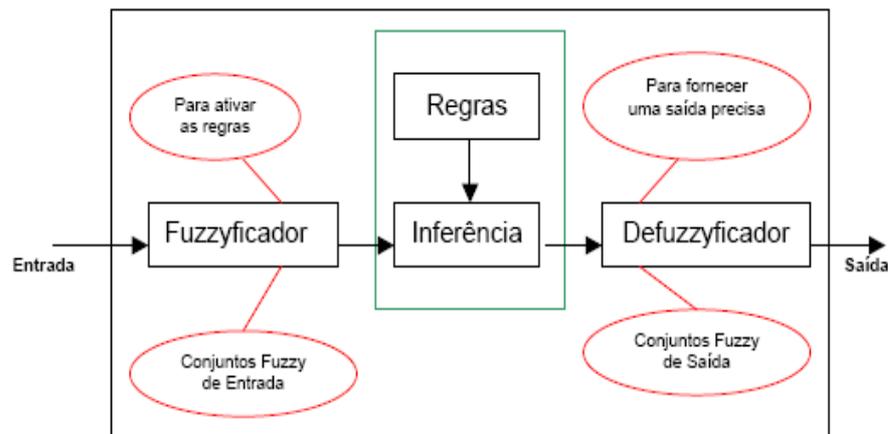
Cada mapa componente é uma representação do mapa treinado com referência a apenas uma das variáveis envolvidas, sendo assim, a posição dos neurônios é a mesma em todos os mapas componentes, o que permite a identificação de correlações entre as variáveis. Mapas componentes similares indicam variáveis com correlação forte (VESANTO, 1999).

A fundamentação teórica do SOM, utilizada para o desenvolvimento deste trabalho, está detalhada em Sperandio (2004).

3.5 Lógica Fuzzy

A Lógica Fuzzy introduzida inicialmente por Zadeh, em 1965, também conhecida como lógica difusa pode ser entendida como uma extensão da lógica booleana, onde valores intermediários entre o conjunto fechado $[0,1]$ fazem parte da base de sua fundamentação matemática (ZADEH, 1965). Esta metodologia pode traduzir sistematicamente o conhecimento linguístico e qualitativo para números e vice-versa. Algoritmos Fuzzy são bem aplicáveis a situações em que entre uma verdade e uma falsidade absoluta existem possibilidades intermediárias não completamente falsas nem completamente verdadeiras. A Figura 8 mostra um sistema clássico de inferência Fuzzy:

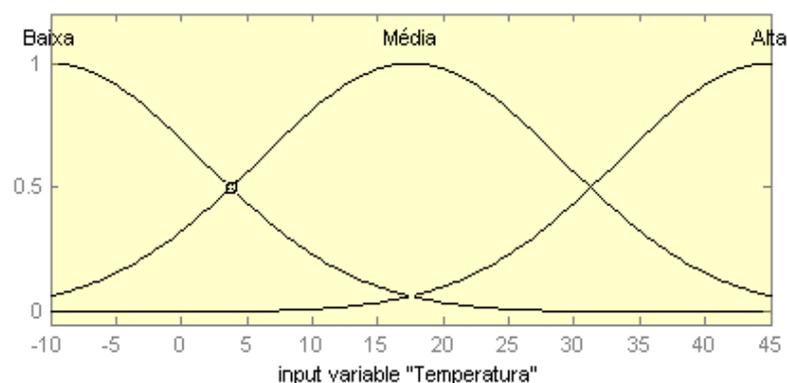
Figura 8 - Sistema de Inferência Fuzzy.



Fonte: Andrade, 2010.

Como geralmente os dados de entrada são valores precisos, resultados de medições ou observações, é necessário efetuar-se um mapeamento destes dados precisos para os conjuntos Fuzzy de entrada, conhecido como fuzzyficação. Essa consiste em atribuir valores linguísticos às variáveis de entrada e associá-la a funções que podem ser retangulares, trapezoidais ou gaussianas entre outras. Estas funções são chamadas de funções de pertinência. Por exemplo, seja a variável temperatura estabelecida dentro de um intervalo de -10°C a 45°C . A temperatura pode ser fuzzyficada por meio de três funções de pertinência. A cada função é associado um valor linguístico (baixa, média e alta). A Figura 9 ilustra este processo.

Figura 9 - Fuzzyficação.



Fonte: Nose, Lotufo, Lopes, 2008.

No estágio de inferência ocorrem as operações com conjuntos Fuzzy propriamente ditas: combinação dos antecedentes das regras (variáveis), implicação e regra de inferência composicional. Neste estágio ocorre também a ativação das regras para uma dada situação. Para o problema de previsão de séries temporais a inferência baseada no método de Sugeno é usualmente utilizada (NOSE; LOTUFO; LOPES, 2008).

As regras Fuzzy nada mais são do que um conjunto de proposições SE - ENTÃO associados às variáveis de entrada. Uma vez obtido o conjunto Fuzzy de saída através do processo de inferência, no estágio de defuzzyficação é efetuada uma interpretação da informação. Nesta etapa, os valores linguísticos são convertidos para valores numéricos. Os conjuntos Fuzzy de entrada, relativos aos antecedentes das regras, e o de saída, referente ao conseqüente, podem ser definidos previamente ou, alternativamente, gerados automaticamente a partir dos dados, como ocorre em sistemas adaptativos do tipo *Adaptive Network Fuzzy Inference System* (ANFIS), abordado a seguir. Vale ressaltar que, a experiência humana aliada à obtenção de dados reais é fundamental para o desenvolvimento de um sistema Fuzzy confiável, na escolha das variáveis, composição das regras, determinação do processo de inferência e interpretação da variável de saída. A maior desvantagem da Lógica Fuzzy é que esta técnica nem sempre proporciona uma solução exata para um problema, sendo que em alguns casos tal solução é necessária.

Para a solução específica de problemas de previsão de séries temporais, a Lógica Fuzzy costuma ser utilizada em conjunto com algoritmos de Redes Neurais, resultando em um sistema híbrido chamado de Sistema Neuro-Fuzzy.

3.6 Redes Neuro-Fuzzy

Redes Neuro-Fuzzy são sistemas híbridos compostos por conceitos de conjuntos Fuzzy aliados a algoritmos de aprendizagem conexionista propiciado pelas Redes Neurais Artificiais (RNA). Este sistema possui as vantagens destas metodologias tendo a capacidade de generalização no reconhecimento e classificação de padrões das RNA, além de sua característica adaptativa. Associado a isto, a facilidade no entendimento de um determinado problema, já que a Lógica

Fuzzy o modela utilizando abordagem linguística próxima da usado por um especialista, torna este sistema híbrido uma ferramenta robusta, podendo ser utilizada para uma vasta gama de aplicações, entre essas à previsão de séries temporais. A união destas duas técnicas torna-se possível pelo fato de ambas serem consideradas aproximadores universais manipulando dados imprecisos, complexos e não lineares.

Com o advento das redes Neuro-Fuzzy, o conceito de “caixa preta” comumente atribuído às RNA é rompido, já que o comportamento da rede neural pode ser entendido por meio de variáveis linguísticas, funções de pertinência, relação entre entrada e saída e regras Fuzzy. Deste modo, o sistema pode ser entendido de forma mais intuitiva, devido à simplicidade e proximidade da linguagem Fuzzy com a linguagem humana.

Dentre as estruturas Neuro-Fuzzy mais empregadas para solução de problemas de engenharia destacam-se o *Fuzzy Adaptive Learning Control* (FALCON) e o *Adaptive Network Fuzzy Inference System* (ANFIS). Esta última, proposta por Jang (1993), é o que possui maiores aplicações para a solução de problemas de classificação e previsão. A seguir será descrita brevemente a arquitetura do sistema ANFIS.

3.6.1 Adaptive Network Fuzzy Inference System (ANFIS)

Basicamente, um sistema ANFIS opera de modo a utilizar o aprendizado de uma rede neural para determinar parâmetros Fuzzy, ajustando as funções de pertinência e base de regras. Este sistema Fuzzy é treinado por uma RNA de caráter adaptativo e posteriormente torna-se capaz de prever dados de séries temporais, como é o caso de previsão de carga elétrica a curto, médio e longo prazo. A heurística de aprendizado opera em situações locais causando somente modificações pontuais nos fundamentos Fuzzy. Os conjuntos Fuzzy (funções de pertinência) são codificados como pesos sinápticos das conexões entre os neurônios da RNA.

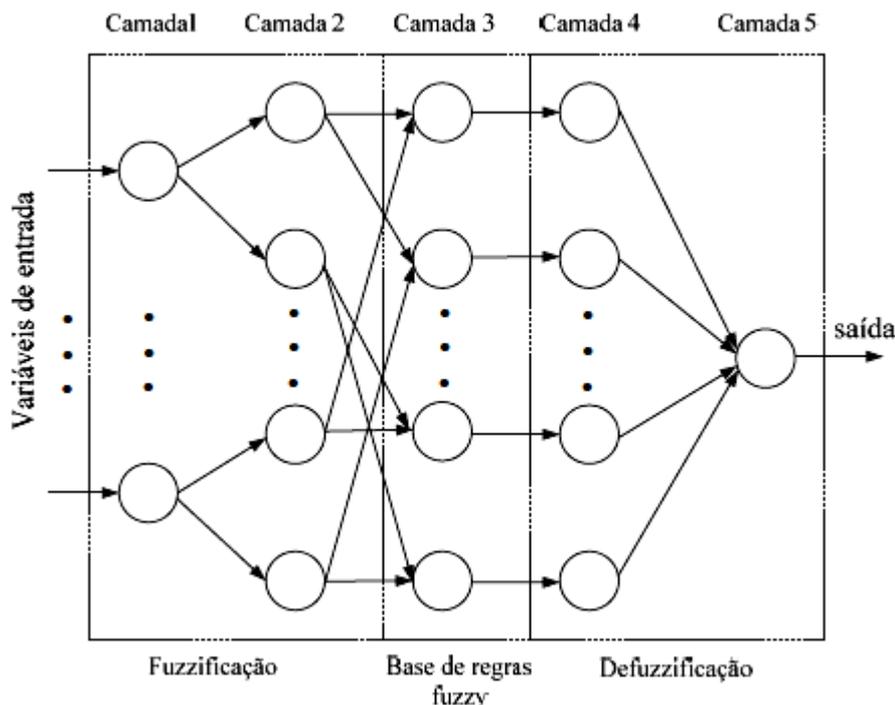
O sistema Neuro-Fuzzy pode ser compreendido como o ilustrado na Figura 8, exceto que a computação de cada estágio é realizada por uma camada oculta de neurônios e a capacidade de aprendizado e adaptação da rede afere melhorias ao

sistema de conhecimento. Um sistema Neuro-Fuzzy pode ser visto como uma RNA de três camadas, descritas a seguir:

- primeira camada: representa as variáveis de entrada onde é realizada a Fuzzyficação. Cada neurônio representa uma função de entrada do antecedente de uma determinada regra;
- segunda camada: representa as regras Fuzzy onde ocorre o processo de inferência. Nesta camada as regras são ativadas sendo que os valores após a aplicação da regra representam o peso sináptico sendo ajustado no período de treinamento;
- terceira camada: representa as variáveis de saída relacionadas à defuzzyficação, onde cada neurônio representa uma posição consequente e suas funções de pertinência podem ser projetadas. O peso de saída da terceira camada representa o centro de gravidade de cada saída da função de pertinência. Por fim, com base no treinamento da rede, o ajuste é feito nos pesos sinápticos dos neurônios e nos limites das funções de pertinência.

A Figura 10 apresenta a estrutura básica de um sistema Neuro-Fuzzy do tipo ANFIS.

Figura 10 - Estrutura de um sistema ANFIS.



Fonte: Nose, Lotufo, Lopes, 2008.

Para o problema específico da previsão de carga elétrica aplicada ao processo de planejamento da operação e expansão de sistemas elétricos, utiliza-se um determinado número de elementos em um vetor de entrada podendo incluir ambos os fatores climáticos, cíclicos, sazonais e atípicos, dependendo da disponibilidade de dados e precisão requerida do modelo a ser desenvolvido. Como exemplo pode ser incluído como variáveis de entrada: a hora, o dia da semana e os N valores de carga. Os valores de entrada costumam ser binários e normalizados dentro de intervalo [0 a 1]. Desta forma, a representação dos 7 dias da semana requer 3 bits de dados, as estações do ano necessitam de 2 bits, as 24 horas do dia necessitam de 5 bits. Para a carga, a normalização em p.u. mostra ser conveniente.

A utilização de redes Neuro-Fuzzy para a previsão de carga de curto e médio prazo com foco no setor elétrico brasileiro pode ser encontrada em (CAMPOS, 2008; NOSE; LOTUFO; LOPES, 2008; TORRES et al., 2006).

4 ANÁLISE DA INFLUÊNCIA DAS VARIÁVEIS CLIMÁTICAS NA PREVISÃO DE DEMANDA A CURTÍSSIMO PRAZO

Conforme visto nos capítulos anteriores, há uma série de fatores que apresentam um efeito significativo na evolução da demanda de energia elétrica, e devem ser incorporados ao modelo de projeção buscando a melhoraria da precisão.

O conhecimento da tendência de comportamento da carga em um horizonte de curtíssimo prazo pode ser considerado como uma previsão em tempo real e é utilizada, por exemplo, para detectar condições de segurança de operação nos sistemas elétricos.

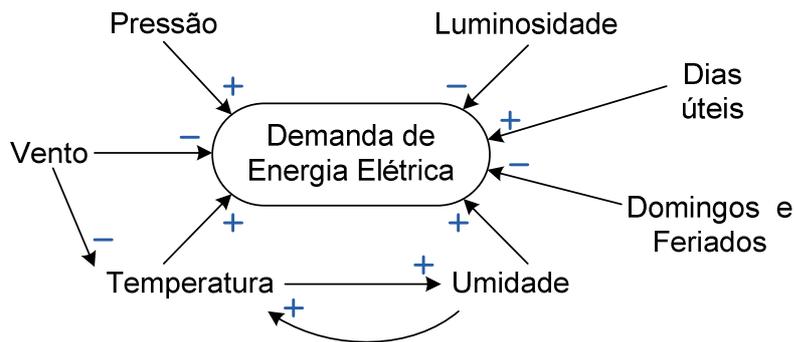
A escolha adequada das variáveis que melhor explicam um dado padrão de carga determinará a adequação do modelo de projeção. Neste sentido, as variáveis consideradas neste projeto são as variáveis climáticas. Estas variáveis apresentam grande relevância em termos de seus efeitos sobre a evolução da demanda de energia elétrica no curtíssimo prazo, uma vez que atuam diretamente sobre a sensação de conforto térmico dos indivíduos e, conseqüentemente, interferem na evolução da demanda.

Definir o conforto térmico não é tarefa simples, pois além dos fatores físicos, envolve uma gama de fatores pessoais que tornam sua definição subjetiva. Segundo o Instituto de Astronomia, Geofísica e Ciências Atmosféricas da Universidade de São Paulo (IAG-USP), o conforto térmico pode ser visto e analisado sob dois pontos de vista: o pessoal e o ambiental. Nesse sentido, considerando somente o ponto de vista pessoal, o IAG-USP define o conforto térmico como sendo uma condição mental que expressa satisfação com o ambiente térmico.

A sensação de temperatura que o corpo humano sente é frequentemente afetada por vários fatores. O corpo humano é uma máquina térmica que constantemente troca energia com o meio ambiente e qualquer fator que interfira na taxa de perda de calor do corpo afeta sua sensação de temperatura. Este fato, conseqüentemente afeta a demanda dado que o indivíduo em estado de desconforto térmico procurará imediatamente adequar o ambiente em que se encontra a uma temperatura mais confortável, utilizando para isso, condicionadores de ar. Além da temperatura do ar, outros fatores significativos que controlam o conforto térmico do corpo humano são: umidade relativa, vento e radiação solar.

A Figura 11 ilustra as principais variáveis climáticas relacionadas com a variação de demanda, através de relações causais. Pode-se observar que além das variáveis climáticas existem variáveis cíclicas e sazonais que também apresentam influência sobre a carga.

Figura 11 - Diagrama de relações causais que influenciam a demanda de energia elétrica.



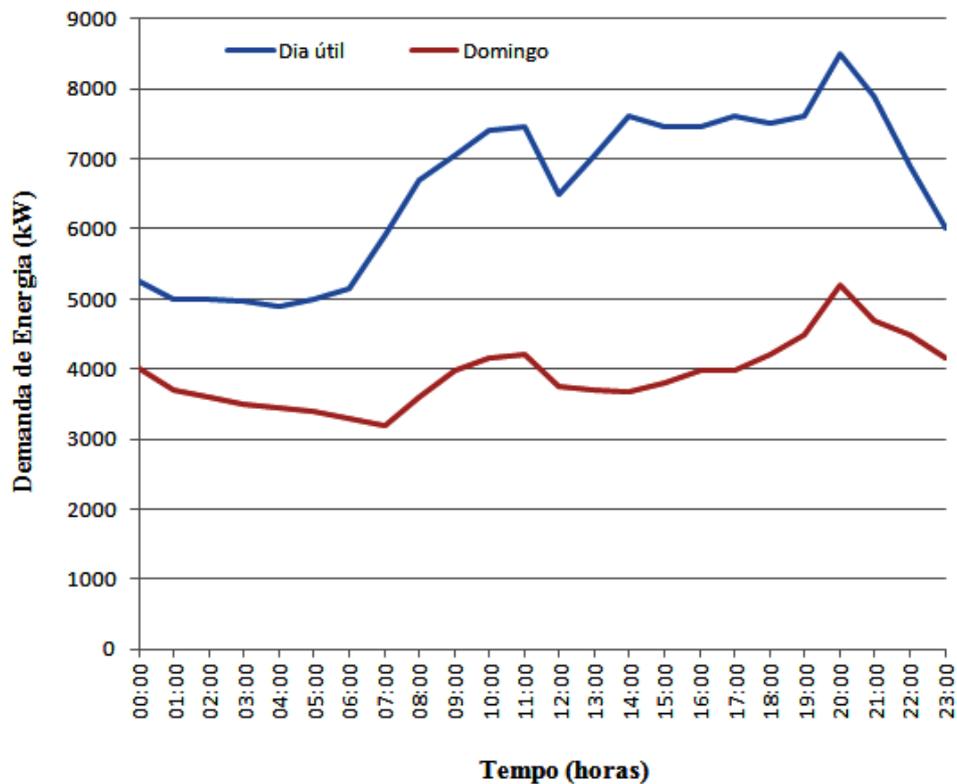
Fonte: Oliveira et al., 2010.

Os estudos dos dados de demanda de energia elétrica junto a dados meteorológicos contribuem no entendimento da influência das variáveis climáticas sobre a evolução da demanda. Os resultados, apresentados a seguir, foram obtidos considerando valores reais de demanda, temperatura, umidade, e velocidade do vento, sendo obtidos a partir da base de dados disponibilizada por uma pequena concessionária de distribuição de energia elétrica no período de 2007 a 2009.

4.1 Determinação dos padrões de carga elétrica

Nos estudos de projeção de demanda elétrica é importante avaliar e definir as características dos perfis diários de demanda. Esta análise auxilia a compreensão da evolução da demanda de energia elétrica ao longo do tempo. Nesse sentido, com base no banco de dados previamente consolidado e considerando o comportamento da carga durante toda uma semana pode-se definir três padrões para os perfis de demanda: um para dias úteis, um para sábados e outro domingos/feriados. A Figura 12 ilustra os perfis padrões de carga para um dia útil e um domingo.

Figura 12 - Perfis de carga típicos para um dia útil e domingo.



Fonte: Bordignon, 2012

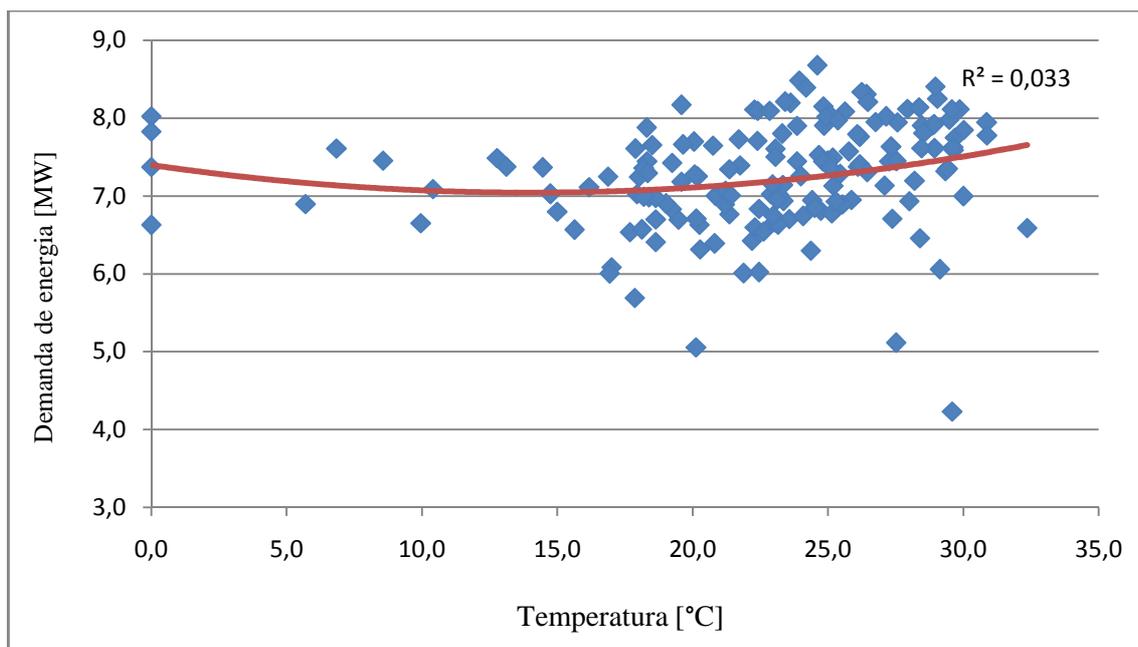
Cabe salientar que o principal interesse desta análise é determinar quais os padrões de demanda de energia para um período determinado, dado que, geralmente, esses padrões são similares para todo o ano. Os perfis apresentados na Figura 12 são apenas ilustrativos, dado que, embora eles sejam valores reais com perfis que se assemelham ao longo do tempo, os valores de máximo (pico) mudam para as diferentes estações do ano.

4.2 Relação entre demanda, temperatura ambiente e umidade relativa do ar

Dentre as variáveis climáticas a Temperatura Ambiente (TA) é a mais significativa em relação a sua influência sobre a carga elétrica no contexto dos consumidores residenciais e comerciais. Um pequeno desvio da TA em relação a seu valor normal (considerado como 23°C no Brasil) gera uma variação significativa no consumo de eletricidade. Para demonstrar isto, na Figura 13 representa-se a

evolução da carga elétrica com a variação de temperatura média. Nesta figura, os pontos representam os valores reais obtidos da base de dados considerada no presente estudo e a linha contínua representa a tendência da variação de uma variável em relação à outra.

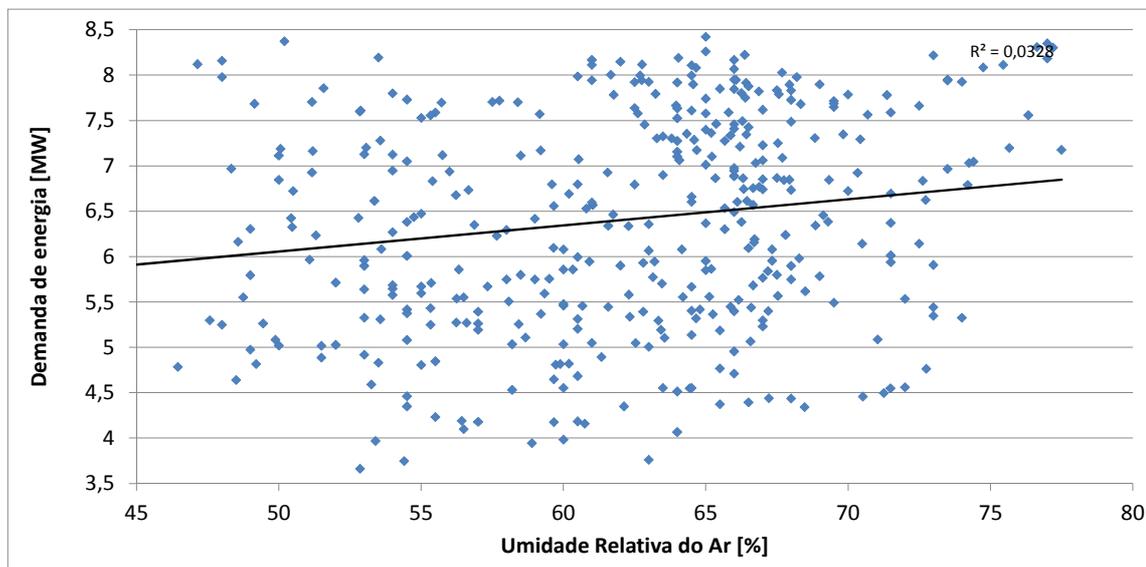
Figura 13 - Regressão entre a temperatura média e a demanda de energia.



Fonte: Bordignon, 2012.

Além da temperatura, a Umidade Relativa do ar (UR) é outra variável meteorológica que afeta o nível de demanda elétrica. A Figura 14 ilustra o seu efeito sobre a demanda com o gráfico de regressão entre a carga máxima e a UR média em um dado período.

Figura 14 - Regressão entre a umidade média e a demanda de energia.



Fonte: Bordignon et al., 2011.

Em ambas as figuras, pode-se observar que existe uma correlação positiva entre a carga elétrica demandada e as duas variáveis avaliadas, isto é, a demanda de energia elétrica aumenta com o aumento da temperatura e/ou o aumento da umidade relativa do ar, esta última também relacionada com dias muito nublados ou chuvosos, que exigem maior iluminação artificial.

4.3 Índice de desconforto

A combinação da Temperatura Ambiente (TA) e da Umidade Relativa do ar (UR) determina a sensação de conforto do corpo humano. Estas variáveis são normalmente as variáveis climáticas mais utilizadas quando se procura definir níveis de desconforto. O Índice de Desconforto (ID) é uma expressão proposta no trabalho de Thom¹, que combina em um único valor numérico os efeitos da temperatura, umidade e o movimento do ar sobre a sensação de calor ou frio sentida pelo corpo humano. No entanto, anos mais tarde D'archivio² propôs outra expressão que

¹ THOM, E. C., "The discomfort index," Weatherwise, 1959.

² D'ARCHIVIO, S., "Interazione animale-ambientale e criteri di progettazione degli edifici per l'allevamento ai fini della riduzione dello stress da caldo," Tese de doutorado – Universidade de Bologna, Italia, 2007.

permite o uso direto dos valores de temperatura e umidade. Assim, o ID é expresso como apresenta a Equação 7:

$$ID = T_A - 0,55 \cdot \left(1 - \frac{U_R}{100} \right) \cdot (T_A - 14) \quad (7)$$

onde, ID é o índice de desconforto térmico [°C], T_A é a temperatura [°C] e U_R é a umidade relativa de ar [%].

Em seu trabalho, Thom propôs uma escala de categorias para os índices de desconforto, apresentadas na Tabela 1. Para valores inferiores a 20, tem-se o início de uma sensação de desconforto inverso, ou seja, quando o corpo humano começa a sentir frio.

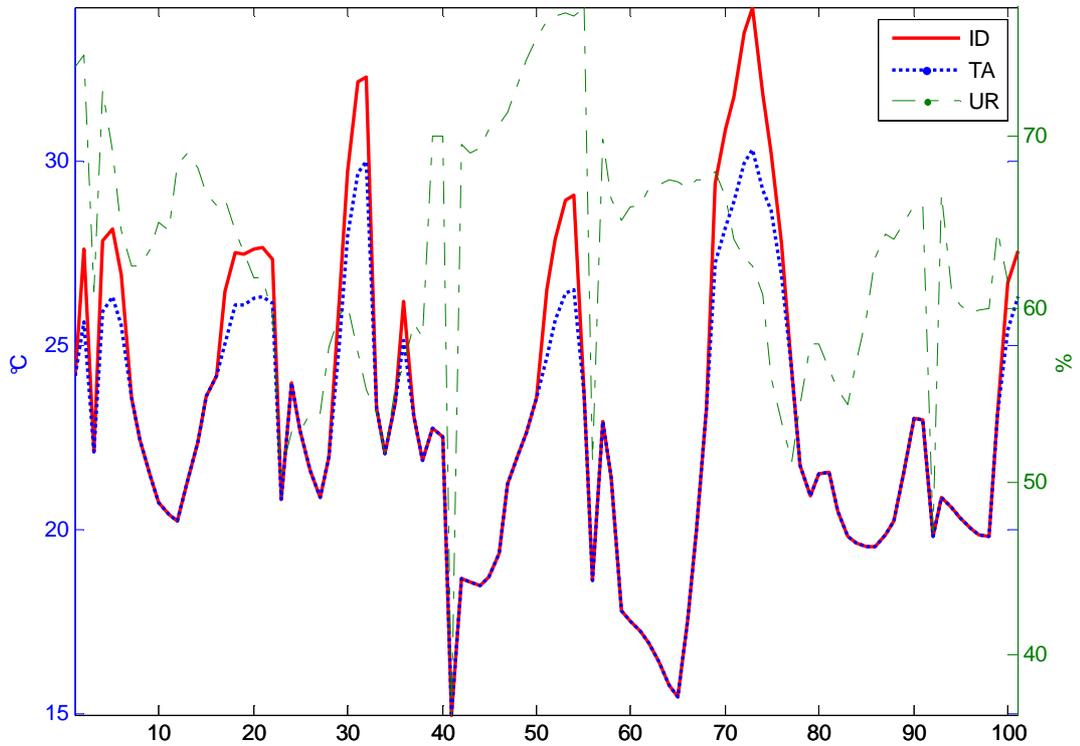
Tabela 1- Categorias dos índices de desconforto térmico.

Valor de ID	Sensação
ID < 21	Confortável
21 ≤ ID < 24	10% da população sente desconforto
24 ≤ ID < 26	50% da população sente desconforto
ID ≥ 26	100% da população está desconfortável
ID > 26,7	Desconforto muito forte e perigoso

Fonte: Oliveira et al., 2010.

A Figura 15 apresenta a variação do ID e da temperatura ambiente no decorrer de um dia útil completo. Pode-se observar que a variação do ID é similar à variação da temperatura ao longo do dia, fato que permite estudar a variação de carga elétrica diretamente em relação à variação do ID, dado que este parâmetro considera, além do valor da temperatura, a variação da umidade relativa do ar.

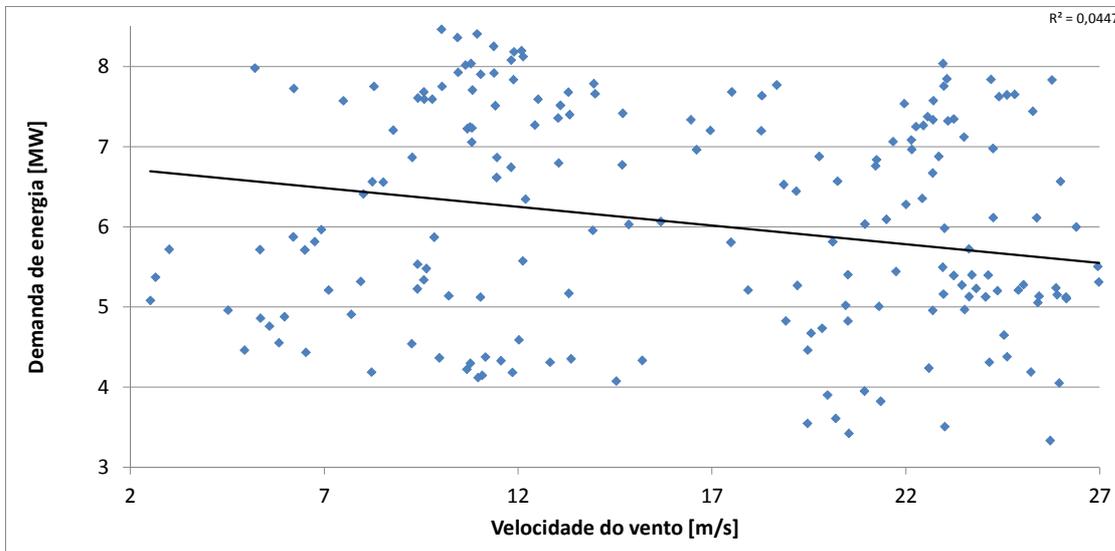
Figura 15 - Variação do ID, temperatura e umidade ao longo de 100 horas.



Fonte: Bordignon et al., 2011.

4.4 Sensação térmica

É de conhecimento tácito que o vento diminui a sensação térmica, e ao observarmos um gráfico de dispersão pode-se notar a correlação negativa entre velocidade do vento e demanda elétrica (Figura 16).

Figura 16 - Regressão entre a velocidade do vento e a demanda elétrica.

Fonte: Bordignon et al., 2011.

Visando considerar mais variáveis climáticas que expliquem a evolução da demanda, estudou-se outra expressão que relaciona a temperatura ambiente e a Velocidade do Vento (VV). Esta expressão, conhecida como Sensação Térmica (ST), determina a temperatura sentida pelo corpo humano. A ST pode ser calculada através da equação (8):

$$ST = 33 + \frac{(10 \cdot \sqrt{V_V} + 10,45 - V_V)(T_A - 33)}{22} \quad (8)$$

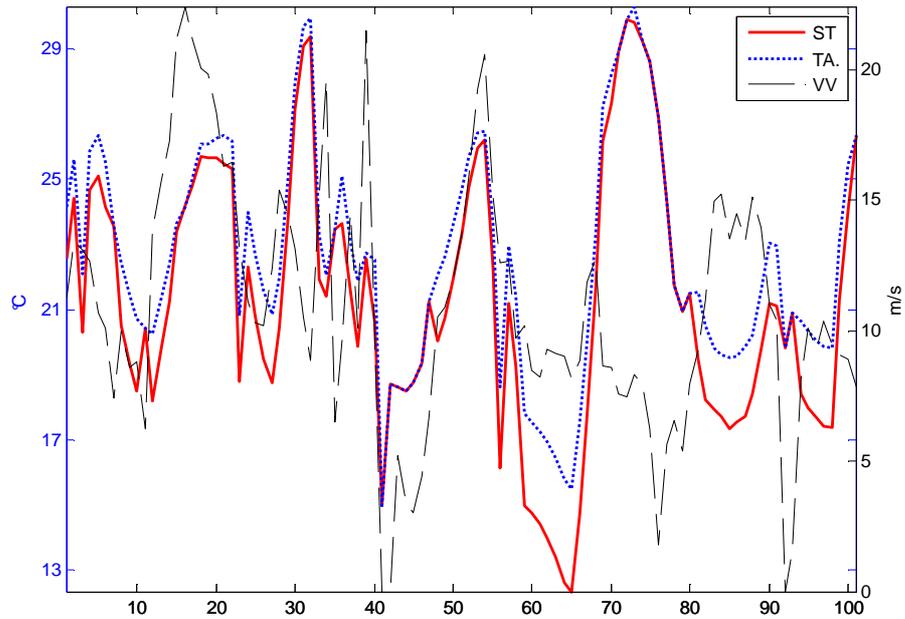
onde, ST é a sensação térmica [°C], T_A é a temperatura do ar [°C] e V_V é a velocidade do vento [m/s].

A Equação 8 foi elaborada a partir da expressão apresentada no trabalho de Kermanshahi et al.³ visando atender o critério de dimensionalidade da ST, geralmente expressa em [°C]. A Figura 17 apresenta a variação da ST, da T_A e da V_V no decorrer de um dia útil completo. Pode-se observar que a variação da ST é

³ KERMANSHAH, B; YOKOYAMA, R; TAKAHASHI, K., "Intelligent Forecasting of distribution System Loads" – *Proceeding of Electrotechnical Conference MELECOM*, vol. 2, pp. 784-787, May 1996.

proporcional à variação da temperatura, contudo, esta variável não acompanha de forma diretamente proporcional a variação da velocidade do vento, sendo mais influenciada quando este fica acima de 8 m/s.

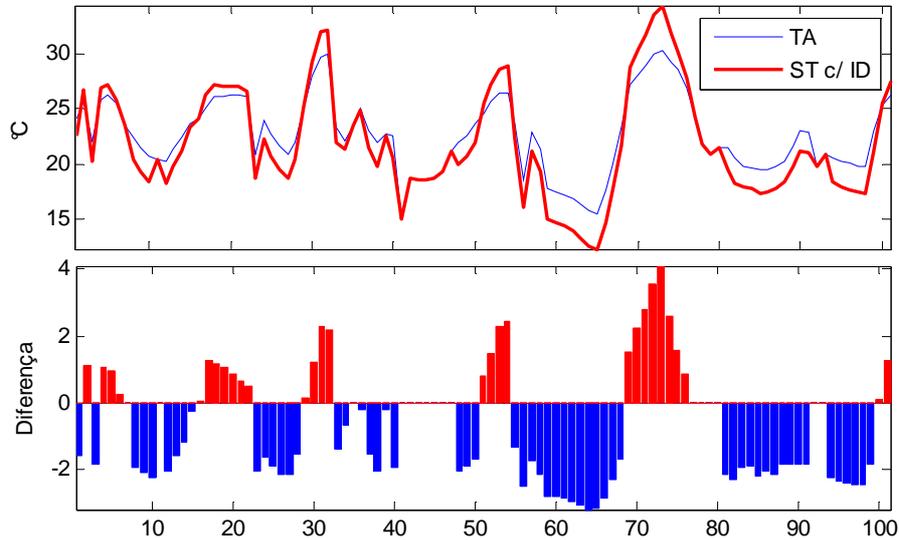
Figura 17 - Variação da ST, da TA e da VV ao longo de 100 horas.



Fonte: Bordignon et al., 2011.

No entanto, é interessante avaliar a ST em função do ID ao invés de TA, isto é, foi substituído na Equação 8 a TA por ID (Figura 18):

Figura 18 - Variação da ST em função do ID e diferença para a temperatura ambiente ao longo de 100 horas.



Fonte: Bordignon et al., 2011.

Pode-se observar na Figura 18 que a ST com ID varia acima e abaixo da temperatura ambiente, dependendo da umidade relativa e velocidade do vento. Alta umidade e baixo vento aumentam a sensação de calor, enquanto baixa umidade e elevado vento diminuem a temperatura percebida. Para umidade média ($40 < UR < 50$) e baixo vento ($VV < 8$) a ST é praticamente igual a TA.

A partir dos resultados deste projeto, identificou-se que o ID e a ST são indicadores adequados para projeção de carga elétrica a curtíssimo prazo, dado que consideram satisfatoriamente os efeitos das principais variáveis climáticas sobre a evolução da demanda de energia elétrica. Salienta-se que estes dois índices (ST e ID) estão relacionados diretamente com a sensação de desconforto térmico de um indivíduo, que por sua vez tem correlação positiva com a necessidade de condicionamento do ambiente, se refletindo diretamente na demanda de energia elétrica. Além disso, com o estudo do efeito do ID e da ST sobre a evolução da demanda é possível relacionar-se em dois únicos valores os efeitos individuais das variáveis climáticas consideradas.

5 METODOLOGIA PROPOSTA

Este trabalho propõe o desenvolvimento de uma ferramenta computacional a partir de pesquisas que buscarão como resultado uma metodologia inovadora para previsão de carga. Esta metodologia levará em consideração a influência de novas variáveis para relacionar as condições climáticas no processo de previsão de carga usando os conceitos de Índice de Desconforto e Sensação Térmica. Os dados históricos de demanda total e das variáveis climáticas serão agrupados em neurônios com a aplicação de Mapas Auto-Organizáveis – SOM (*Self-Organizing Map*). A partir da classificação dos dados históricos do SOM, será criado um modelo probabilístico discreto, com a utilização da cadeia de Markov, que irá permitir a realização das previsões de carga a curtíssimo prazo, através da análise da probabilidade de transições dos neurônios ao longo do tempo.

A opção por realizar a previsão de demanda total, e não por segmento de mercado, se deu em função da disponibilidade dos dados de demanda em tempo real, por meio das medições de fronteira da empresa. Esta metodologia pode ser desdobrada por segmento de mercado quando os medidores inteligentes forem uma realidade no Brasil, o que certamente reforçará a validade da previsibilidade da projeção.

A utilização da rede neural do tipo SOM para realizar o agrupamento das variáveis de entrada (demanda e climáticas) em neurônios, em detrimento às outras metodologias de agrupamento existentes, se justifica por ser esta uma metodologia que permite a atualização dos valores de previsão de carga, a partir dos dados medidos em tempo real, que servem para realimentar os Mapas Auto-Organizáveis e os modelos de Markov.

Desta forma o sistema atua de maneira independente e em tempo real, se adaptando automaticamente a qualquer condição de carga. Este fator é de grande valia para a previsão de carga no horizonte de curtíssimo prazo, para empresas que possuem grande sensibilidade das cargas, ou seja, onde a entrada ou saída de funcionamento de um único grande consumidor, já pode causar um impacto significativo na demanda do seu Sistema Elétrico. Além disso, a utilização do SOM permite a identificação de correlações entre as variáveis, o que possibilita uma análise mais apurada do comportamento da demanda nas variadas condições climáticas.

A metodologia proposta apresentará outro diferencial que será a informação da probabilidade de violação do valor da demanda contratada a partir das previsões de carga. Isso possibilitará à concessionária definir medidas a serem tomadas com o propósito de evitar a ultrapassagem do valor contratado da demanda como, por exemplo, a melhor agenda de despacho de uma PCH, principalmente quando há estiagem. Para isso serão realizados testes simulando o despacho de uma PCH em patamares controlados com base nas probabilidades de ultrapassagem de demanda contratada, obtidas do modelo de Markov, construído a partir do histórico das variáveis de demanda e clima, agrupados pelo Mapa Auto-Organizável. A Figura 19 mostra o fluxograma simplificado da metodologia de previsão de carga.

Figura 19 - Fluxograma da metodologia de previsão de demanda.

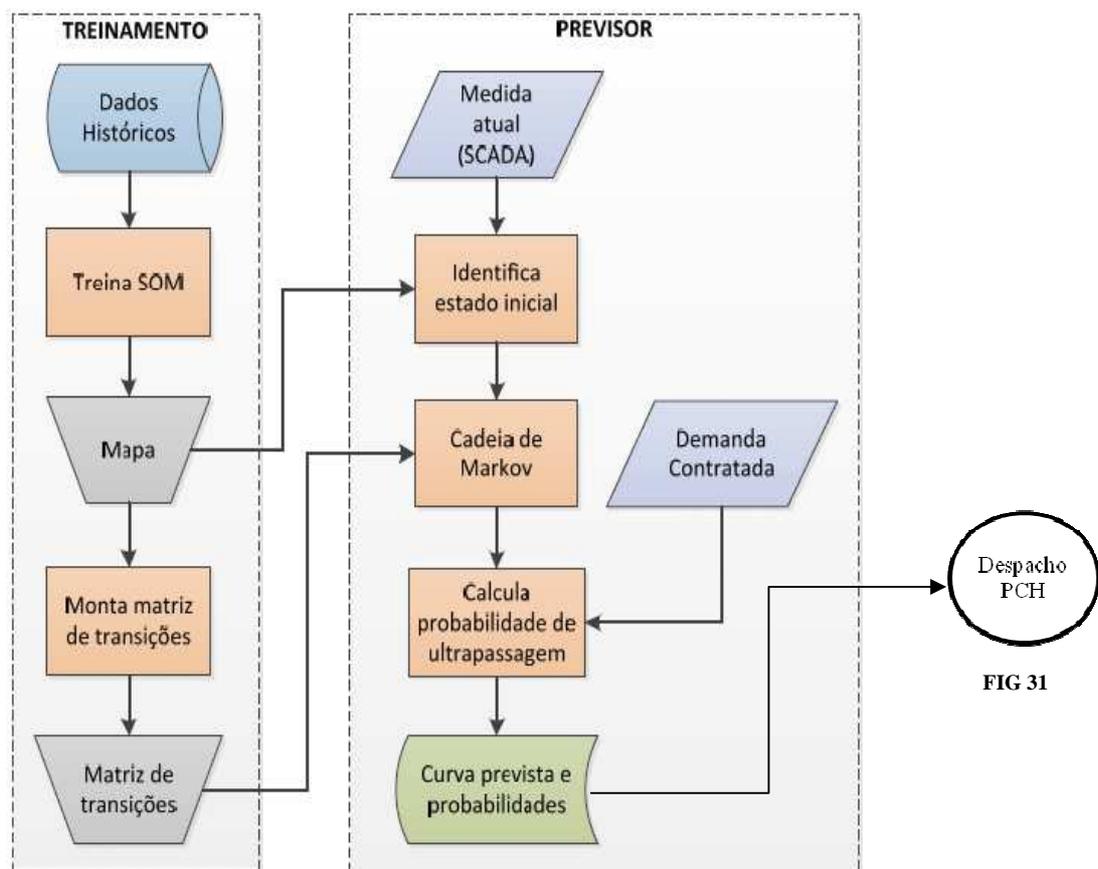


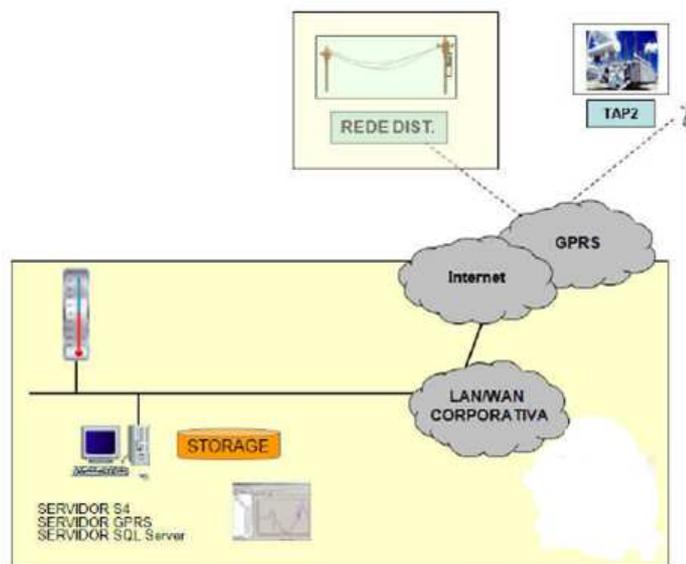
FIG 31

Fonte: Bordignon, 2012.

Desta forma, se tivermos as medições de demanda atual e das variáveis climáticas, em tempo real, o que será possível com a utilização de um sistema

SCADA (*Supervisory Control and Data Acquisition*), o SOM alocará este vetor de dados em um determinado neurônio, que será o estado inicial para a cadeia de Markov. Várias transições serão simuladas pelo sistema, para se obter a curva de carga, permitindo assim, a visualização do comportamento futuro da carga no horizonte de curtíssimo prazo, e calcular a probabilidade de ultrapassagem da demanda contratada com a Supridora. Como o sistema SCADA receberá, em tempo real, os valores da demanda e das variáveis climáticas, será possível realizar a previsão de carga adaptativa, isto é, a previsão de carga é atualizada em períodos horários, conforme os valores reais verificados. A Figura 20 ilustra a estrutura do sistema SCADA para a aquisição de dados.

Figura 20 – Estrutura do sistema SCADA para aquisição dos dados.



Fonte: Sperandio et al., 2011.

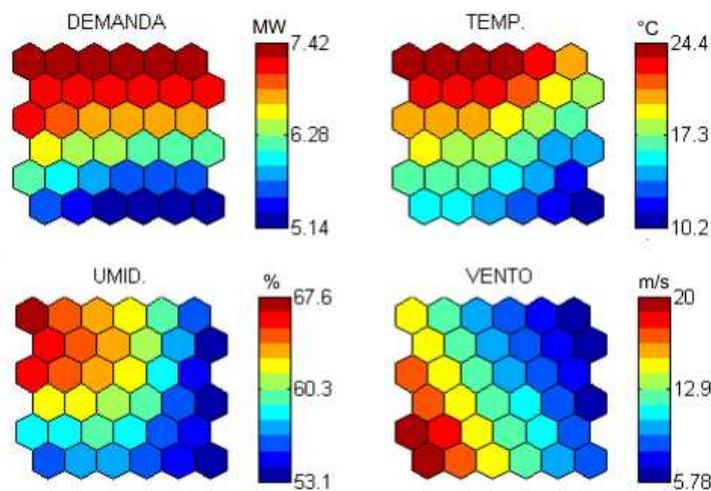
5.1 Aplicação do SOM na metodologia proposta

Como foi citado anteriormente, o SOM será aplicado para o agrupamento das variáveis de entrada (demanda e climáticas) em neurônios. A Figura 21 apresenta os mapas componentes para a classificação de 3.290 medidas horárias de demanda, temperatura, umidade do ar e velocidade do vento em uma rede com 36 neurônios (6x6). A cor vermelha indica os maiores valores, enquanto o azul os menores. A

escala ao lado do mapa indica o valor médio das variáveis, demanda em MW, temperatura em °C, umidade em % e velocidade do vento em m/s.

Na Figura 21 é possível se identificar algumas relações entre as variáveis, como por exemplo, no canto superior esquerdo, tem-se elevada demanda, elevada temperatura, elevada umidade e vento intermediário. Já no canto inferior esquerdo, onde predominam as velocidades de vento maiores, verifica-se uma baixa demanda.

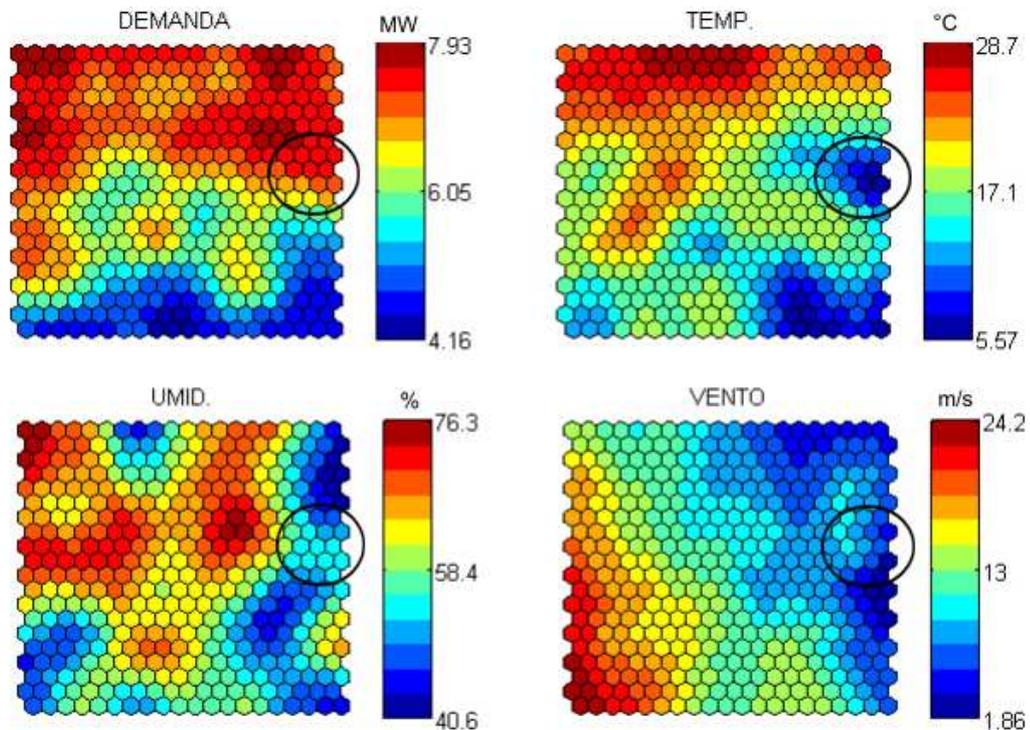
Figura 21 - Mapas componentes 6x6 para as quatro variáveis estudadas.



Fonte: Bordignon et al., 2011.

No caso de mapas maiores, com uma maior relação de neurônios por dado de entrada, se obtém uma maior dispersão topológica capaz de revelar relações entre variáveis que não aparecem em dimensões menores. A Figura 22 mostra um mapa 20x20 treinado com a mesma base de dados da Figura 21.

Figura 22 – Mapas componentes 20x20 para as quatro variáveis estudadas.



Fonte: Bordignon et al., 2011.

Na Figura 22 já é possível se observar novas relações que não eram evidentes nos mapas da Figura 21, como por exemplo, na região mais a direita e no centro do mapa (circulada), onde a demanda é elevada, a temperatura é baixa e a umidade e o vento são baixos, o que caracteriza dias de inverno no Rio Grande do Sul, em que a população deve ter recorrido a aquecedores elétricos. Isso mostra uma tendência inversa entre temperatura e demanda também, o que torna um modelo de previsão linear falho sob estas condições.

Desta forma, se utilizará os Mapas Auto-Organizáveis no processo de previsão de carga, com a finalidade de construir neurônios para agrupar as medidas semelhantes. A Tabela 2, a seguir, apresenta as quatro variáveis das sete amostras que foram agrupadas em um dos neurônios dessa região comentada anteriormente, onde se pode observar a homogeneidade dos dados classificados.

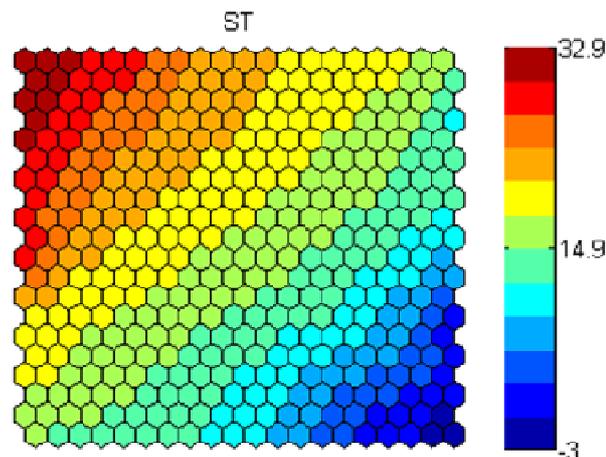
Tabela 2 - Dados agrupados por um dos neurônios da Figura 22.

Código da Amostra	Demanda (MW)	Temperatura (°C)	Umidade (%)	Velocidade Vento (m/s)
83	7,111	5,76	54,40	14,26
90	7,025	5,74	59,50	12,12
91	7,365	5,95	60,67	12,52
2814	7,053	8,29	59,50	14,12
2969	7,628	6,69	66,50	14,41
2972	7,557	6,80	65,50	14,15
2979	7,919	5,81	56,78	13,63

Fonte: Bordignon et al., 2011.

Assim, as amostras, inclusive as novas, serão sempre alocadas para o neurônio mais semelhante, considerando as medidas de demanda, temperatura, umidade e velocidade do vento.

Uma alternativa é usar o Índice de Desconforto e Sensação Térmica em substituição das variáveis climáticas. Assim, é possível relacionar-se em dois únicos valores os efeitos das variáveis climáticas consideradas. A Figura 23 apresenta o mapa componente com 20x20 neurônios treinados a partir da base de dados de variáveis climáticas convertidas para o valor de sensação térmica, com o índice de desconforto.

Figura 23 - Mapa componente 20x20 para sensação térmica.

Fonte: Bordignon, 2012.

5.2 Construção do modelo de Markov para previsão de carga

Um modelo de Markov representa um processo estocástico, geralmente com estados discretos e contínuos no tempo, em que o sistema é modelado a partir de parâmetros observáveis. A proposta então é que este modelo possa ser usado para realizar análises da evolução dos estados ao longo do tempo. Parte-se do princípio de que os estados anteriores são irrelevantes para a predição dos estados seguintes, desde que o estado atual seja conhecido.

Uma cadeia de Markov é uma seqüencia $X_1, X_2, X_3, \dots, X_n$ de variáveis aleatórias. O escopo destas variáveis, isto é, o conjunto de valores que elas podem assumir, é chamado de espaço de estados, onde X_n denota o estado do processo no tempo n . Se a distribuição de probabilidade condicional de X_{n+1} nos estados passados é uma função apenas de X_n , então:

$$\Pr(X_{n+1} = x | X_0, X_1, X_2, \dots, X_n) = \Pr(X_{n+1} = x | X_n) \quad (9)$$

Se o modelo está em um estado y no tempo n , então a probabilidade de que se mova para o estado x no tempo $n + 1$ não depende de n , e somente depende do estado atual y em que se está. Assim em qualquer tempo n , uma cadeia de Markov finita pode ser caracterizada por uma matriz de probabilidades cujo elemento (x, y) é dado por (10) e é independente do tempo n .

$$\Pr(X_{n+1} = x | X_n = y) \quad (10)$$

Um espaço de estados é representável por uma matriz de transição, com o (i, j) -ésimo elemento igual a (11):

$$P_{ij} = \Pr(X_{n+1} = j | X_n = i) \quad (11)$$

Para um espaço de estados discretos, as integrações na probabilidade de transição de k passos são somatórios, e podem ser calculados como a k -ésima

potência da matriz de transição. Isto é, se P é a matriz de transição para um passo, então P^k é a matriz de transição para a transição de k passos.

Na medida em que o tempo avança, os valores de probabilidade de se encontrar cada um dos estados tendem a um valor limite constante. Portanto, esses valores de probabilidade limite são independentes do tempo, e a soma resulta em 1.

5.2.1 Exemplo de um modelo de previsão de demanda

Em um exemplo bem simples, se observado que a demanda é baixa em uma determinada hora, a probabilidade de que ela será alta na próxima hora é 0,5. Se a demanda é alta, de outra forma, a probabilidade dela ser baixa na hora seguinte é igual a 0,25.

As transições entre demandas alta e baixa podem ser modeladas como uma cadeia homogênea de Markov, e a matriz de transição de probabilidade é dada pela Tabela 3.

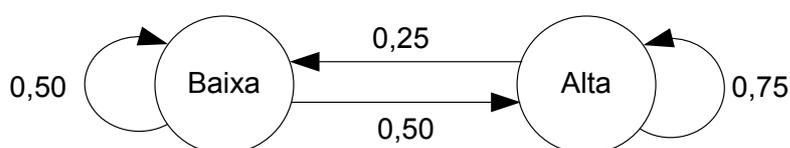
Tabela 3 - Exemplo de uma matriz de transição (P) para dois estados de demanda.

Carga	Baixa	Alta
Baixa	0,50	0,50
Alta	0,25	0,75

Fonte: Bordignon et al., 2011.

Quando o número de estados é pequeno, é conveniente representar um diagrama de transições como o da Figura 24.

Figura 24 - Diagrama de estados de uma cadeia de Markov com a matriz de transição da Tabela 3.



Fonte: Bordignon et al, 2011.

Definido o modelo e a matriz de transições P , pode-se então calcular a probabilidade do sistema estar em um estado após um determinado número de intervalos de tempo com a seguinte equação:

$$P(n)=P(0).P^n \quad (12)$$

onde:

$P(n)$ = vetor com as probabilidades de cada estado;

$P(0)$ = vetor com as probabilidades do estado inicial;

P = matriz de transição;

n = num. de intervalos de tempo após o estado inicial.

Assim, por exemplo, conhecendo-se o estado atual como de demanda baixa, as probabilidades do sistema estar em cada estado após quatro intervalos de tempo são definidas da seguinte forma:

$$P(4) = [1 \ 0] \cdot \begin{bmatrix} 0,5 & 0,5 \\ 0,25 & 0,75 \end{bmatrix}^4 = [0,334 \ 0,666] \quad (13)$$

Ou seja, dado que o sistema estava com demanda baixa, após quatro intervalos de tempo (horas), a probabilidade da demanda ser baixa é de 33,4% e de ser alta é de 66,6%.

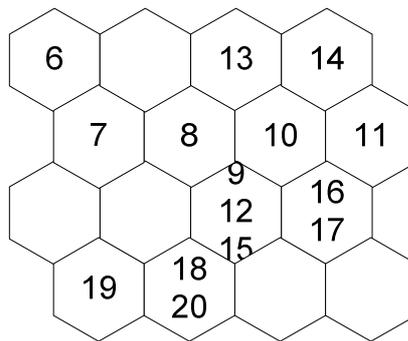
5.3 Atribuição de estados a partir do SOM

Para criar um modelo de Markov a partir de medidas de demanda e variáveis climáticas é necessário se estabelecer estados discretos. Uma forma de definir estes estados é utilizar um método de agrupamento, sendo usado neste trabalho o Mapa Auto-Organizável (SOM). Neste caso, cada neurônio do SOM representa um estado do modelo de Markov, permitindo obter a probabilidade de transição dos estados (neurônios) a cada período de tempo.

Assim, a proposta é treinar um Mapa Auto-Organizável com um histórico de medidas das variáveis desejadas e então definir cada neurônio como um estado

para um modelo de Markov. A matriz de transição P é construída verificando-se a troca de neurônios a cada passo de tempo (intervalos horários) das amostras medidas, ou seja, o caminho percorrido pelo mapa, como exemplificado pelos dados da Tabela 4 distribuídos no mapa da Figura 25.

Figura 25 - Mapa 4x4 com os dados da Tabela 4.



Fonte: Bordignon et al., 2011.

Tabela 4 -Exemplo de medidas horárias para as quatro variáveis observadas.

Hora	Demanda (Mw)	Temperatura (°C)	Umidade (%)	Velocidade Vento (m/s)
6	5,00	8,78	57,00	22,34
7	5,92	9,10	59,50	20,80
8	6,84	9,96	61,11	22,53
9	7,38	11,14	62,44	21,13
10	7,62	13,10	64,42	19,40
11	7,64	15,34	65,71	18,36
12	6,54	17,53	65,46	16,72
13	6,64	18,53	65,00	14,35
14	7,48	18,40	65,00	11,68
15	7,29	18,34	65,00	11,78
16	7,62	17,91	65,00	8,00
17	8,31	13,22	61,98	5,04
18	8,78	14,36	66,56	2,16
19	7,93	14,18	71,14	7,20
20	7,46	14,00	76,00	10,35

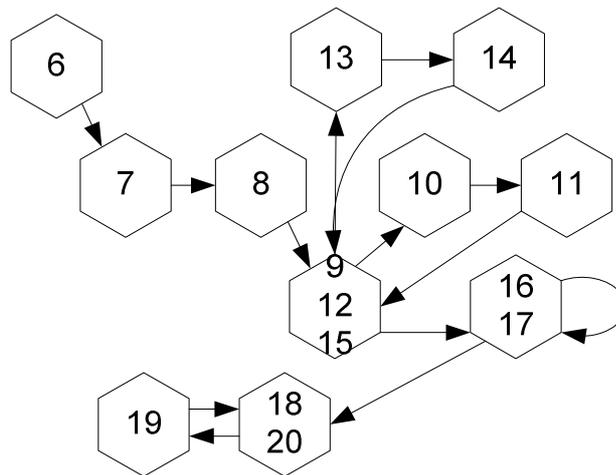
Fonte: Bordignon et al., 2011.

Com o mapa treinado, e considerando cada neurônio como um estado para o modelo de Markov, o passo seguinte é verificar a distribuição da sequência de

amostras pelos neurônios, computando as transições de um neurônio para outro, a fim de formar a matriz de transições P. Dessa forma, observa-se a sequência horária das amostras, como por exemplo, no mapa da Figura 25, a amostra das 6h está alocada no neurônio de número 1, já a amostra seguinte (7h) transitou para o neurônio 2 e a amostra das 8h foi parar no neurônio 6.

A taxa de transição de um estado i para outro j será igual ao número de saídas para o estado j dividido pelo número total de visitas ao estado i . A Figura 26 exemplifica as transições entre neurônios:

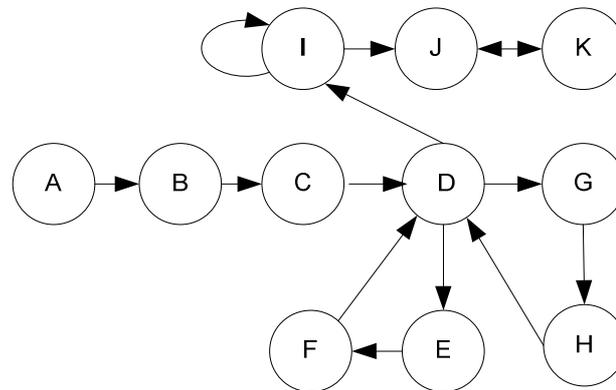
Figura 26 - Transições entre neurônios conforme seqüência de dados amostrados.



Fonte: Bordignon et al., 2011.

O esquema da Figura 26, representando as transições dos dados entre neurônios, pode ser redesenhado como um diagrama de estados de um modelo de Markov, conforme mostra a Figura 27.

Figura 27 - Modelo de Markov criado a partir do mapa da Figura 25.



Fonte: Bordignon et al., 2011.

O modelo da Figura 27 é apenas uma exemplificação. Para que um modelo de previsão de demanda construído desta forma tenha uma boa assertividade é necessário treinar o SOM com um histórico de medidas de pelo menos um ano, contemplando as quatro estações do ano e também a sazonalidade das cargas, de forma que seja possível construir um espaço de estados representativo. Como o modelo é construído a partir de estados já visitados pelo sistema, seu comportamento tende a reproduzir o histórico. Porém, pode-se incrementar o modelo aumentando o tamanho do mapa a ser treinado, e considerando-se os neurônios não ativados (vazios) com uma probabilidade de transição pequena.

Assim, por exemplo, se tivéssemos como ponto de partida as mesmas medidas da hora 6, o modelo realizaria a previsão de carga respeitando as transições de estados (neurônios) da Figura 27, ou seja, replicaria a ordem de estados da Tabela 4 nos respectivos horários. Porém, considerando um histórico maior de medidas, não necessariamente seria respeitada esta ordem, visto que cada neurônio teria uma probabilidade de transição para outros vários neurônios em função do histórico, ou seja, o neurônio “1”, que contém as medidas da hora 6, poderia ter um histórico de transitar para os estados “E”, “F” e “G”.

5.3.1 Cálculo do desvio das previsões de carga

Para fins de avaliação do desempenho da metodologia proposta neste projeto, será analisado o erro percentual médio das previsões de carga em relação

aos valores de demanda medidos. O referido erro médio pode ser calculado como mostra a Equação 14.

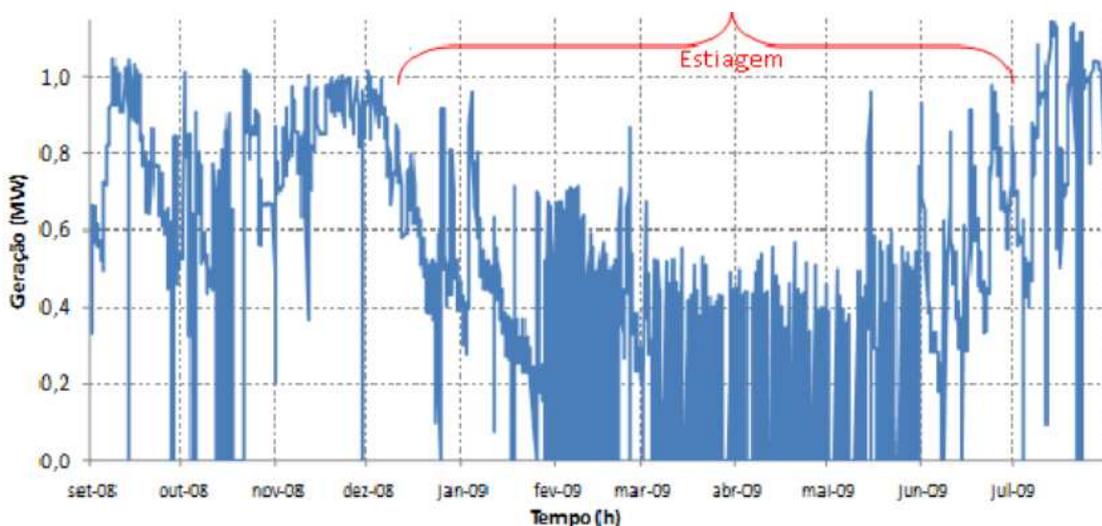
$$E_m = \frac{1}{N} \sum_{i=1}^N \left[\frac{|\hat{L}_i - L_i|}{L_i} \right] \times 100 \quad [\%] \quad (14)$$

onde, N é o horizonte de projeção, L_i é o i-ésimo valor da carga real e \hat{L}_i é o i-ésimo valor da carga projetada.

5.4 Programação do despacho da PCH

Como foi visto anteriormente, as PCH's, geralmente, são usinas hidrelétricas que operam a fio d'água, cujo regime de operação é limitado à pequena capacidade de armazenamento de água do reservatório, o que não permite a regularização do fluxo d'água. Normalmente há restrição de geração no período seco (verão-outono), visto que pode não haver água suficiente para a usina gerar em regime contínuo, como podemos observar na Figura 28, que mostra a evolução da geração da PCH de uma pequena concessionária de distribuição de energia elétrica, em um período de estiagem. Nestas circunstâncias é importante definir intervalos horários para a geração de energia elétrica na PCH.

Figura 28 – Evolução da geração da PCH entre set-2008 e ago-2009.



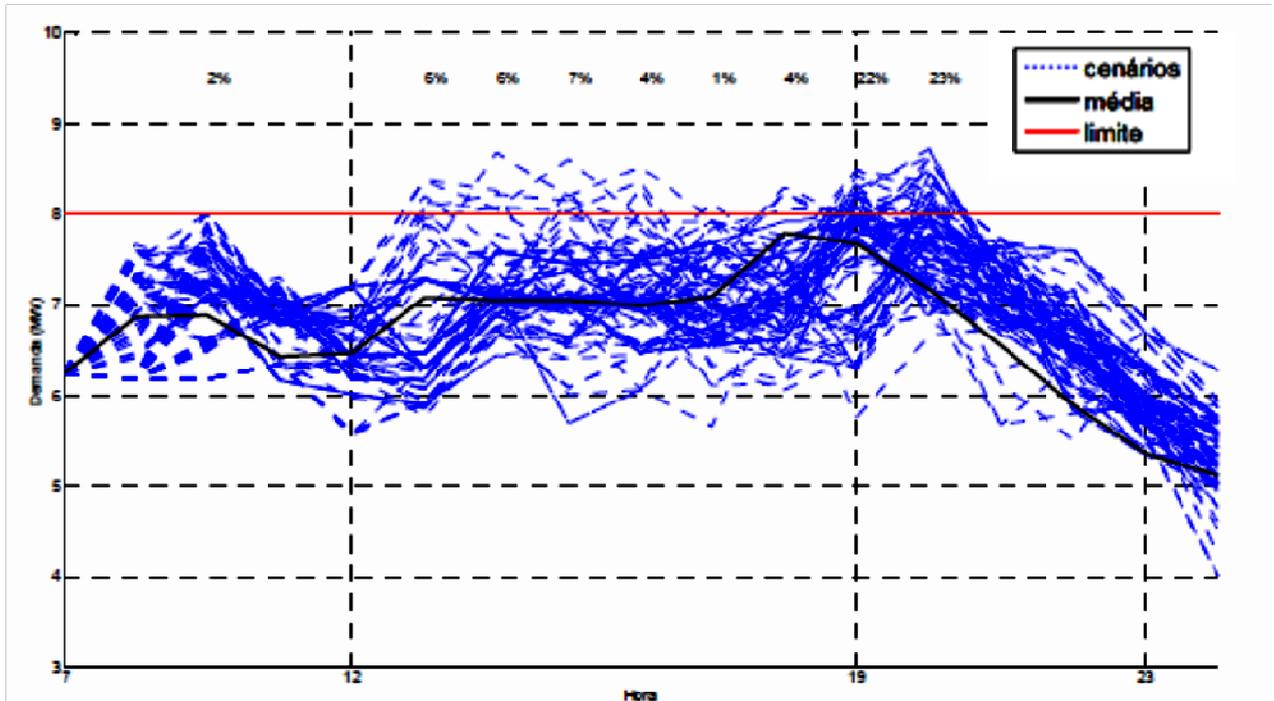
Fonte: Bordignon, 2012.

O método de previsão de carga, horizonte de curtíssimo prazo, desenvolvido neste trabalho, é uma ferramenta de grande valia para a empresa, pois tendo o conhecimento da demanda prevista e da probabilidade de ultrapassagem da demanda contratada, é possível elaborar uma agenda de despacho da PCH, em patamares controlados, priorizando o funcionamento da mesma nos horários onde existe maior probabilidade de ultrapassagem da demanda, já que, nestes períodos críticos de estiagem, não há água suficiente para sustentar a geração por muito tempo.

Para avaliar essa probabilidade, a cadeia de Markov é simulada uma centena de vezes e então é contabilizado o número de cenários que ultrapassou o valor limite, para cada hora do horizonte de estudos. Para ilustrar este processo a Figura 29 mostra a projeção de demanda e cenários para o cálculo de probabilidade, para um dia do mês de setembro desta pequena concessionária de distribuição de energia elétrica. O gráfico, na parte superior, mostra a probabilidade da demanda ultrapassar o limite de demanda contratada, de 8,0 MW, indicado a cada hora, quando o valor da probabilidade for maior que zero, após a simulação da cadeia de Markov.

Observamos que, neste caso, a projeção de cenários para o cálculo da probabilidade de ultrapassagem da demanda contratada ficou em torno de 6% entre 14 e 16 horas e chegou a 23% entre 19 e 20 horas. Portanto, em situações de restrição de geração de energia, com esta previsão de carga, a PCH deverá priorizar o funcionamento no horário entre as 19 e 20 horas, pois é neste horário que existe a maior probabilidade de ultrapassagem de demanda.

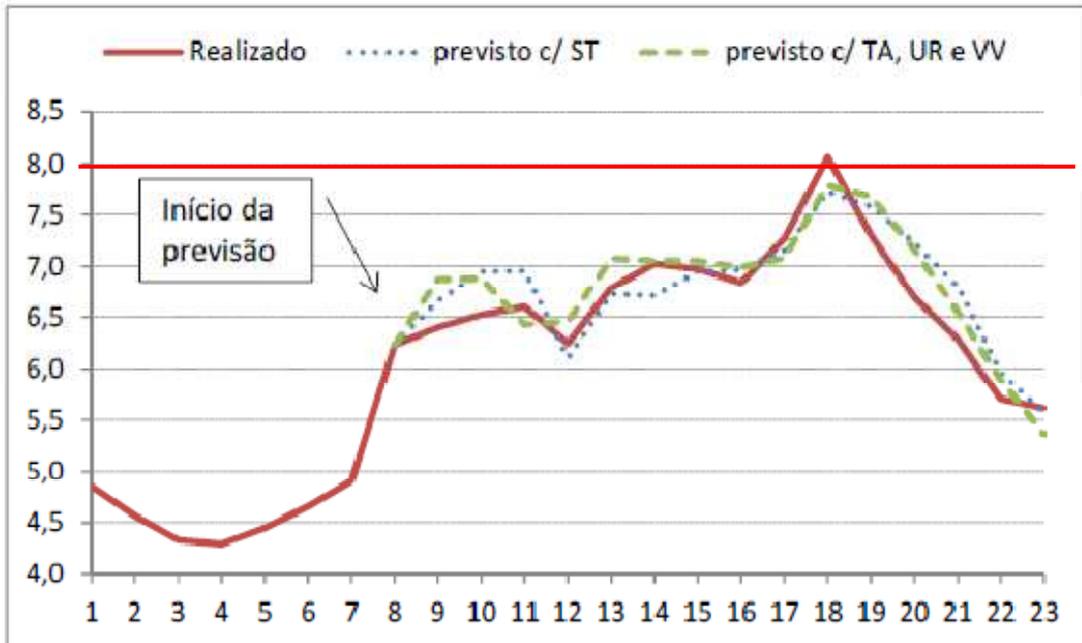
Figura 29 – Projeção de cenários para cálculo de probabilidade para um dia de setembro.



Fonte: Bordignon, 2012.

A Figura 30 mostra a projeção de demanda de energia elétrica, para este dia de setembro, a partir das 8 horas. Os valores utilizados para a projeção são os valores médios obtidos a partir dos cenários da centena de simulações.

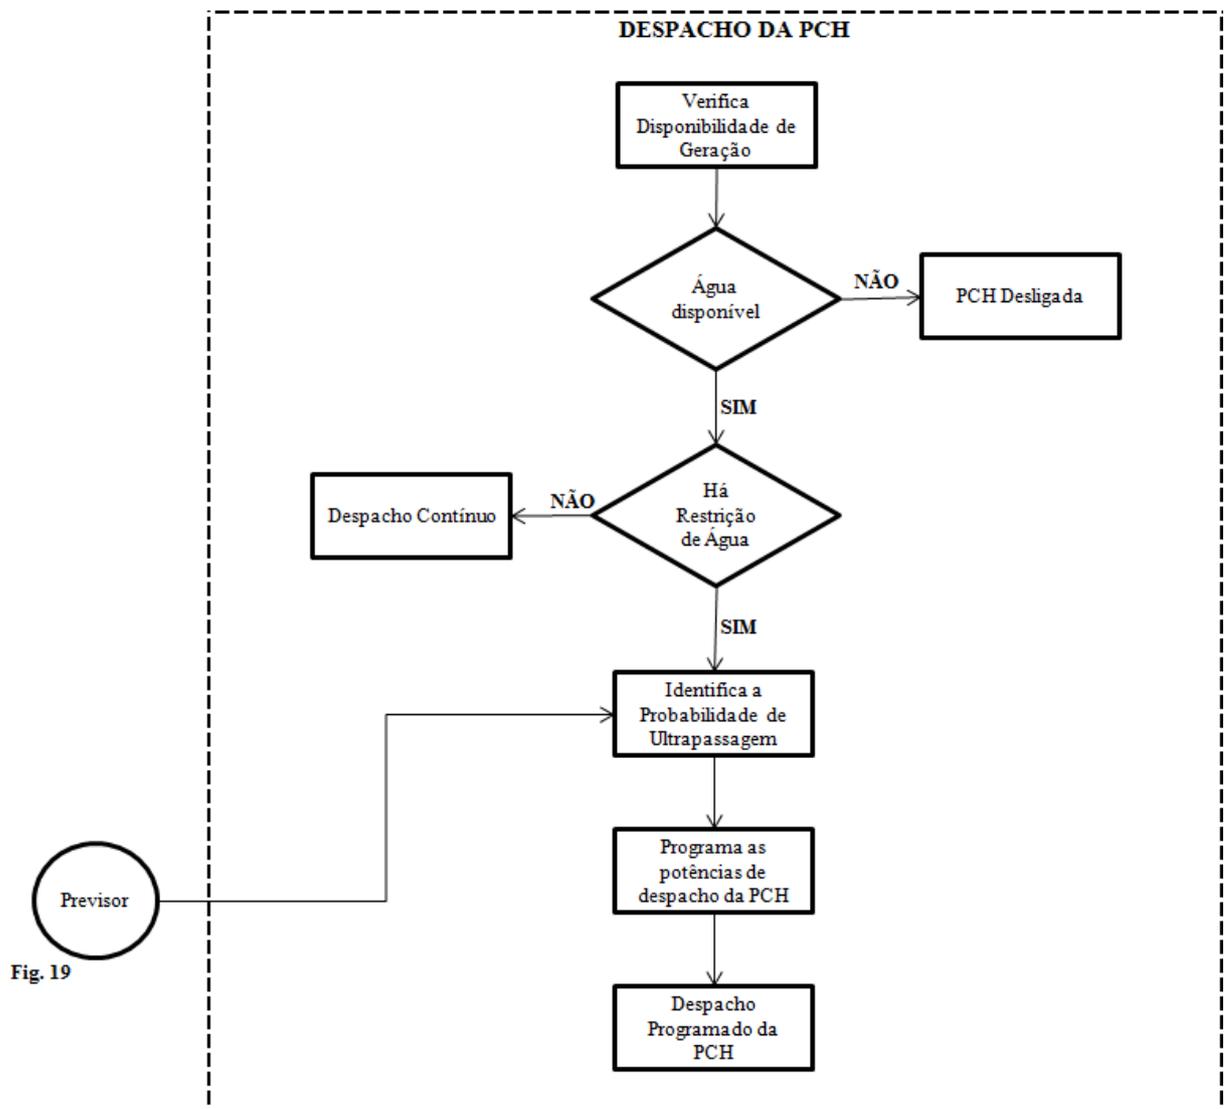
Figura 30 – Projeção de demanda para um dia de setembro.



Fonte: Bordignon, 2012.

Com estas informações é possível programar o despacho da PCH, em diferentes patamares de potência gerada, controlados com base nas probabilidades obtidas no modelo de Markov, construído a partir do histórico das variáveis de demanda e clima agrupados pelo SOM, liberando maior potência gerada para os horários onde a probabilidade de ultrapassagem de demanda for maior e menor potência gerada, ou até mesmo desligar a PCH, nos horários em que houver menor probabilidade de ultrapassagem de demanda. A Figura 31 mostra o fluxograma simplificado da metodologia de despacho, usada em conjunto com a metodologia de previsão de carga (Figura 19).

Figura 31 – Fluxograma da metodologia de despacho da PCH



Fonte: Bordignon, 2012.

Importante ressaltar que, não havendo disponibilidade de água suficiente para geração, a PCH deve permanecer constantemente desligada. Se houver água disponível, sem restrições para geração de energia elétrica, a PCH deve ser mantida constantemente ligada. Porém se houver disponibilidade de água com restrições para a geração de energia, a metodologia acima poderá ser aplicada, visando obter a otimização do despacho da PCH.

Para validar a metodologia de previsão de carga e programação do despacho da PCH, no capítulo seguinte serão realizadas simulações utilizando dados reais ocorridos em uma pequena concessionária de distribuição de energia elétrica do Rio

Grande do Sul, entre os meses de janeiro e março de 2012, quando ocorreu forte estiagem na região, com grande limitação de geração de energia elétrica da PCH.

6 ANÁLISES EXPERIMENTAIS

Neste capítulo será apresentada a aplicação da metodologia desenvolvida bem como os resultados encontrados nos testes para previsão de carga e na elaboração da agenda de despacho da PCH, a fim de avaliar o seu desempenho e sua eficácia. Os testes foram realizados utilizando um sistema protótipo para simular as previsões de demanda e, com os resultados obtidos nestas simulações de carga, elaborar e testar agendas de despacho da PCH.

Os dados utilizados para realizar os estudos foram os valores de demanda realizada fornecida pela supridora e pela PCH de uma pequena concessionária de energia elétrica do Rio Grande do Sul, no mês de dezembro de 2011, período onde ocorreu uma estiagem na região em questão. Além destes dados, foram utilizados os dados reais de temperatura, umidade relativa do ar e velocidade do vento, para realizar a simulação computacional. Esta empresa possuía nesta época, contrato de demanda com a supridora de 8,0 MW.

A simulação foi realizada fazendo uso de uma máquina com processador Intel Core i3- 330M (2,13 GHz, 3MB L3 cache) e 4 GB de memória RAM. O *software* utilizado para a programação da metodologia desenvolvida e para a análise dos resultados foi a linguagem de programação C.

Deste modo, os resultados apresentados a seguir são referentes à previsão de carga a curtíssimo prazo, considerando variáveis climáticas, e elaboração da agenda de despacho de uma PCH, visando o funcionamento da mesma nos horários mais críticos, conforme probabilidade de ultrapassagem da demanda contratada, obtida através da metodologia desenvolvida.

6.1 Previsor de demanda

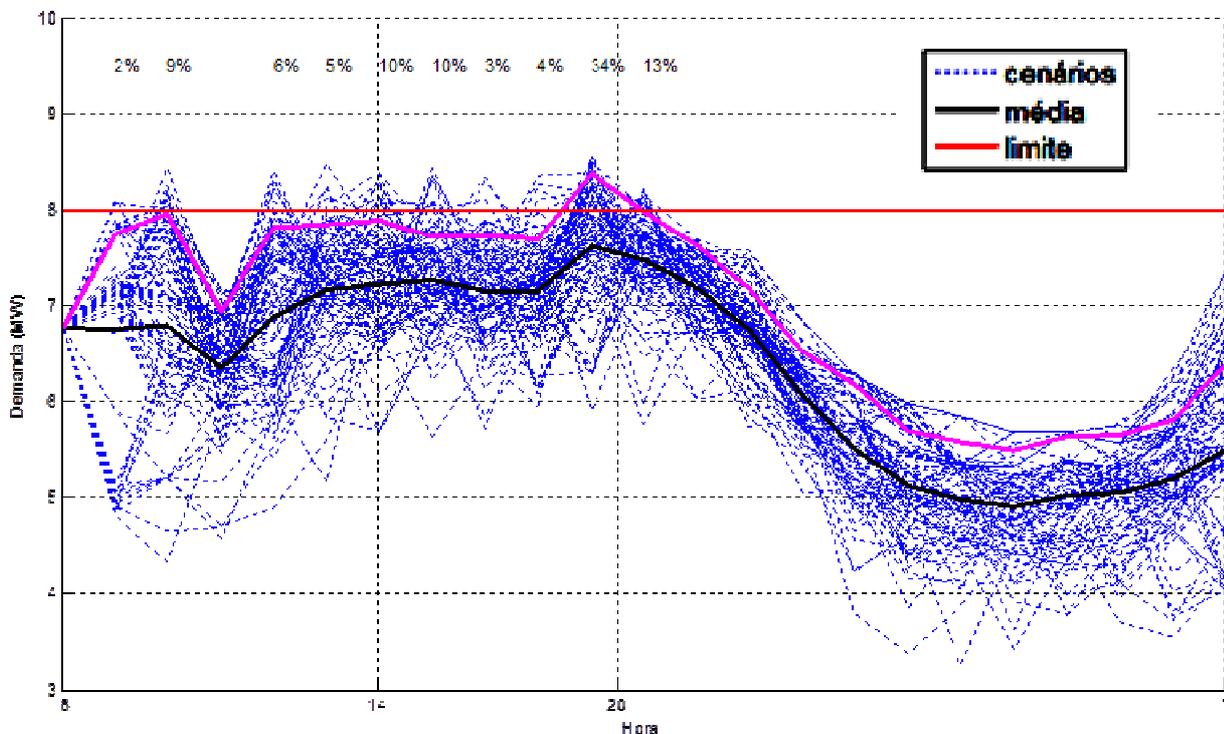
Em termos de previsão de carga, analisou-se o desempenho da metodologia desenvolvida para vários cenários operacionais, no mês de dezembro de 2011, com o objetivo de obter-se o erro médio das projeções e validar a metodologia. Com a metodologia desenvolvida, é possível verificar as probabilidades da demanda atingir um determinado patamar, dentro de um período estipulado.

Para realizar as previsões no protótipo computacional, foram utilizados os dados reais de demanda total, em um horário do início do dia, normalmente entre as

08h00min, que é o horário de início do expediente da empresa, e obtidos os valores projetados de demanda. Estes valores foram comparados com os valores realizados no dia em estudo, para obter-se o erro médio da projeção, utilizando-se a equação (14).

Para um dia útil, do mês de dezembro, os valores de demanda projetados na simulação são os valores médios mostrados na Figura 32. O valor limite é a demanda contratada pela concessionária (8,0 MW).

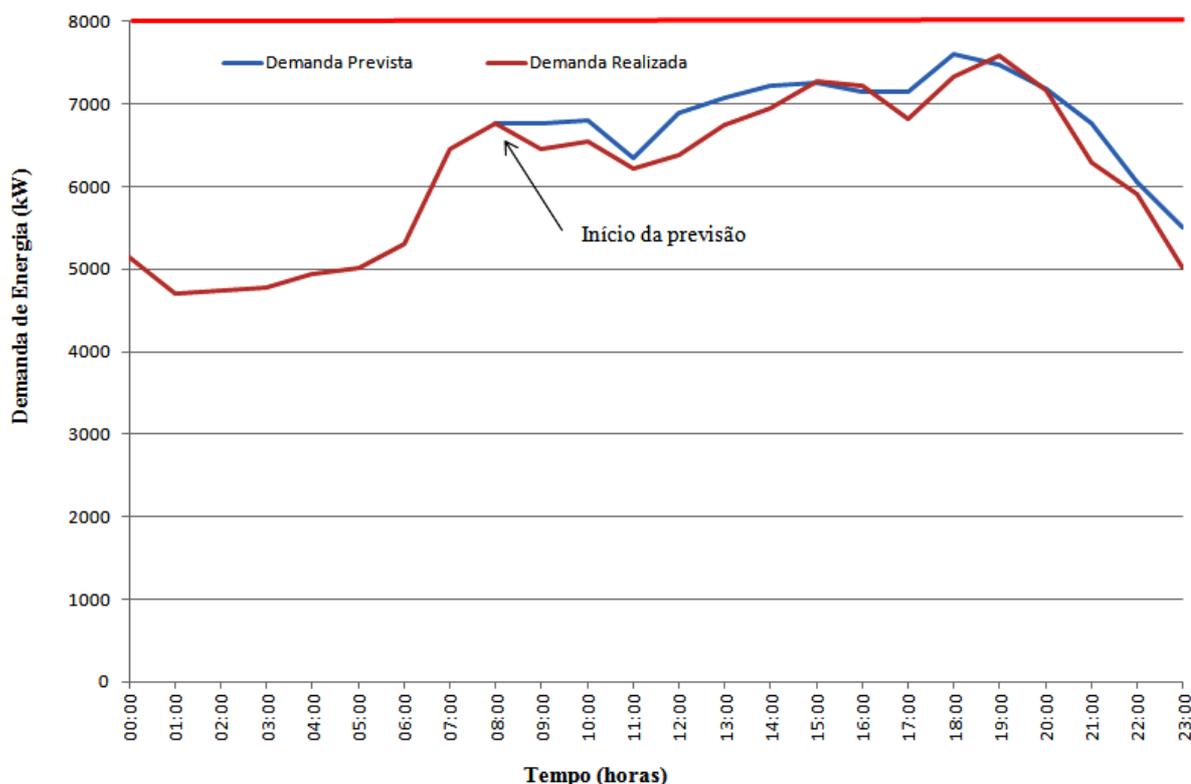
Figura 32 – Projeção de demanda para um dia útil de dez. 2011.



Fonte: Bordignon, 2012.

Comparando os valores obtidos na projeção com medições reais de demanda de energia elétrica para um horizonte até às 23 horas, obteve-se um erro médio de 3,46%, para um dia útil do mês de dezembro de 2011. A Figura 33 ilustra o perfil de demanda para este dia, com previsões a partir das 08h00min da manhã, usando as três variáveis climáticas separadas (temperatura ambiente – TA, umidade relativa – UR e velocidade do vento –VV).

Figura 33 - Perfil de demanda para um dia útil de dez. 2011.



Fonte: Bordignon, 2012.

É importante salientar que, embora a metodologia desenvolvida tenha obtido bons índices para os valores de erro médio, o que dá confiabilidade e estabilidade no processo de predição, estes índices podem ser ainda melhores, já que os resultados obtidos são para aproximadamente 16 horas à frente, sendo que na prática o previsor é atualizado de hora em hora. Como pode se observar nos gráficos acima, o erro médio das projeções para as três primeiras horas, utilizando os mesmos dados de entrada, diminui para 2,59%. Com os valores de entrada sendo atualizados a cada hora, e com o autotreinamento dos mapas, a tendência é de uma diminuição ainda maior deste índice de erro médio.

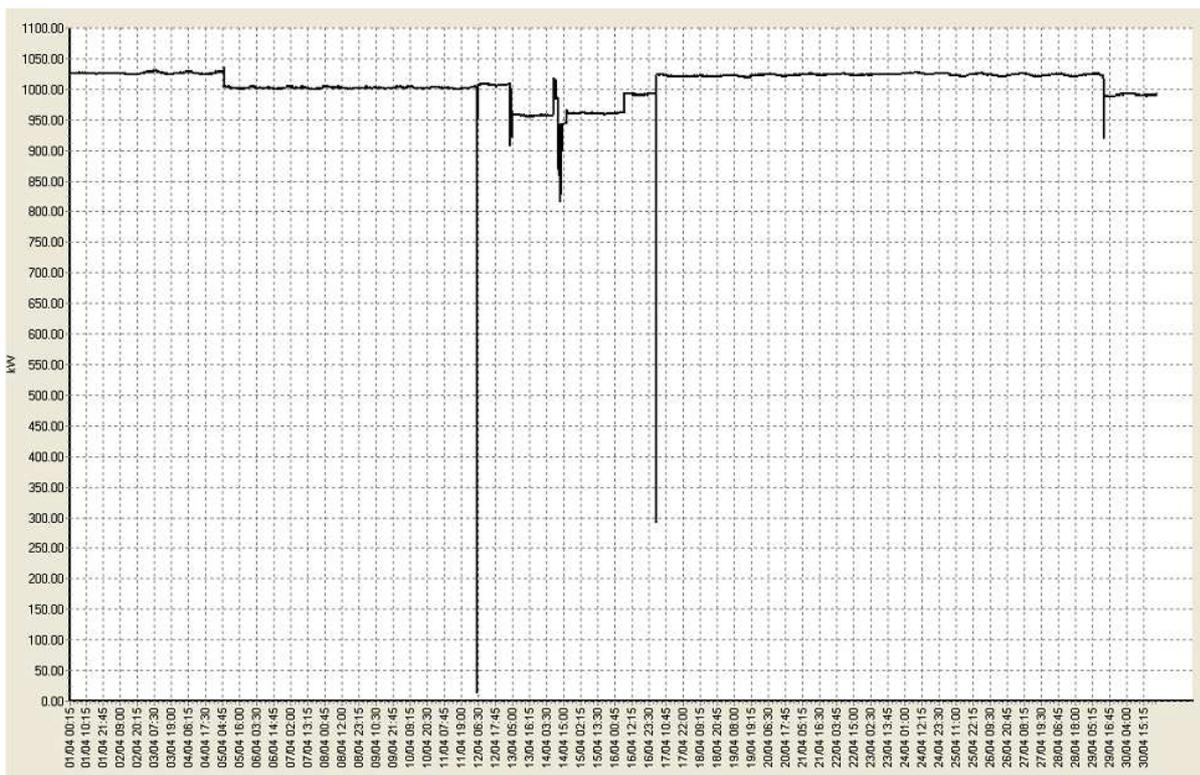
Interessante ressaltar que a data não é variável de entrada, apenas a hora do dia, demanda e variáveis climáticas, e mesmo assim o previsor é capaz de se adaptar continuamente aos diferentes perfis sazonais. As variáveis de entrada do previsor são obtidas em tempo real, pelo sistema SCADA da empresa. Teremos

assim, um previsor de carga que se ajusta a cada hora, tendo como variáveis de entrada, os valores reais de cada variável.

6.2 Agenda de despacho da PCH

Em períodos em que existe água disponível para geração de energia sem restrição, a PCH da empresa pode funcionar em regime permanente, gerando potência máxima ao sistema. A Figura 34 mostra a evolução da demanda gerada pela PCH em um mês de água abundante.

Figura 34 - Evolução da demanda gerada pela PCH em um mês com abundância de água.

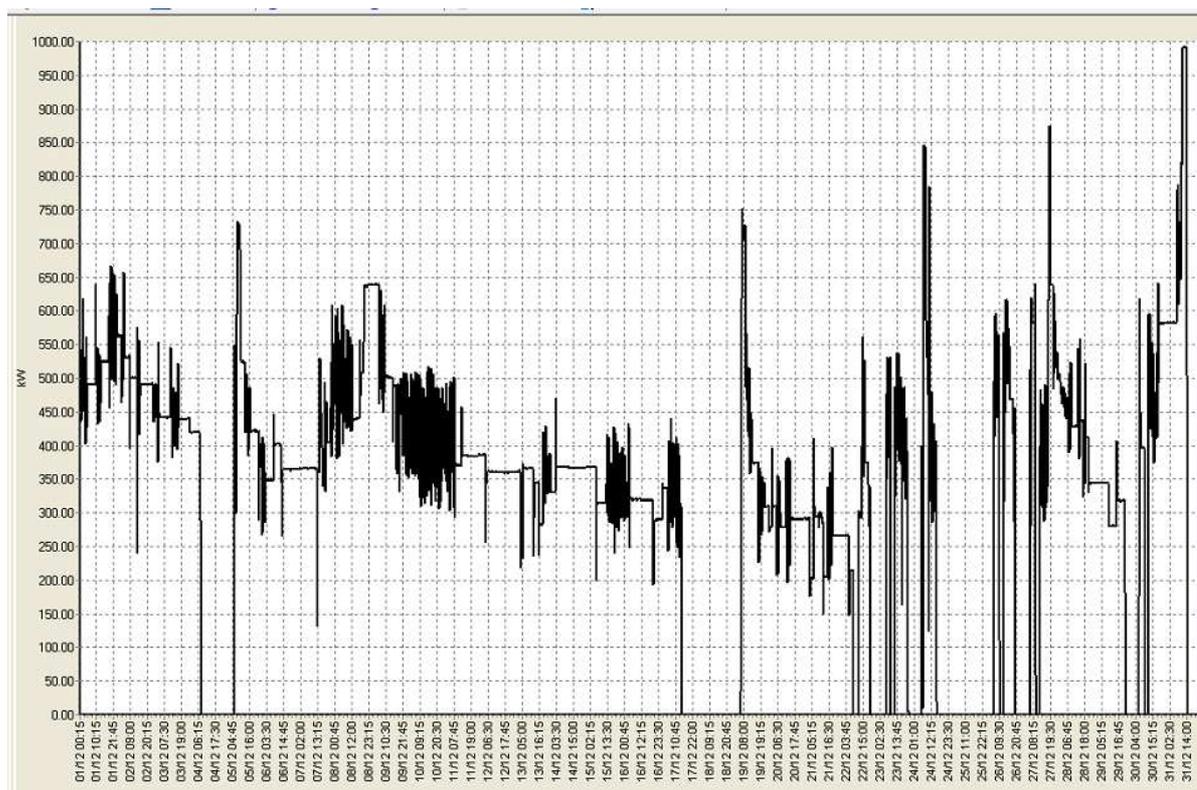


Fonte: Bordignon, 2012.

Porém em períodos de estiagem, como o vivenciado pela empresa em dezembro de 2011, quando a água existente não foi suficiente para sustentar a geração de energia pela PCH por muito tempo, como mostra a Figura 35, é

importante se ter uma previsão de carga a curtíssimo prazo, para poder elaborar uma programação do despacho da PCH em que a mesma esteja funcionando quando a demanda do sistema atingir os maiores valores.

Figura 35 – Evolução da demanda gerada pela PCH em um mês com restrição de água.



Fonte: Bordignon, 2012.

Como a metodologia desenvolvida para a previsão de demanda informa a probabilidade de se ultrapassar a demanda contratada, em cada hora do horizonte de previsão, é possível, com estes dados, elaborar uma agenda de despacho que possibilite o funcionamento da PCH nos horários mais críticos.

Para testar esta aplicação, foram realizados testes simulando o despacho da PCH em cinco patamares de potência gerada, controlados com base nas probabilidades de ultrapassagem da demanda contratada, obtidas no previsor de carga. Para realizar esta simulação, os patamares de despacho da PCH de 1,0 MW escolhidos foram os mostrados na Tabela 5 abaixo.

Tabela 5 - Agenda de despacho da PCH

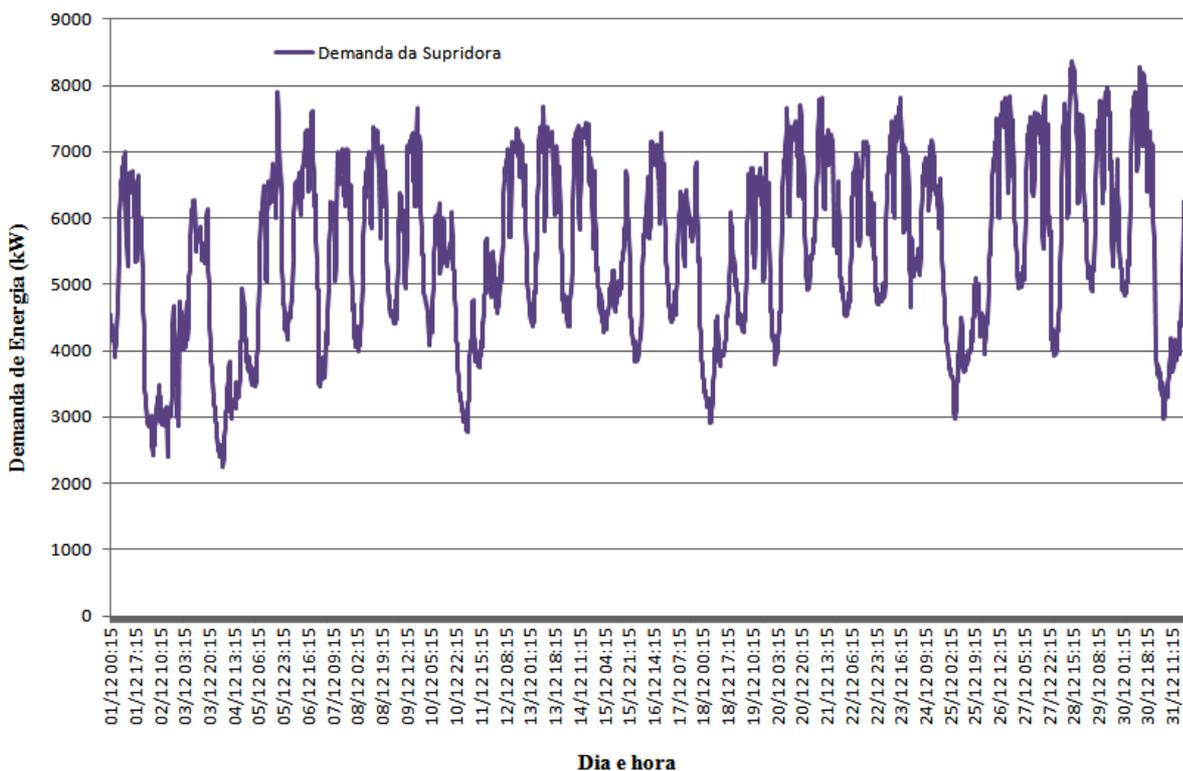
Probabilidade de ultrapassagem da demanda contratada (%)	Potência despachada pela PCH (MW)
De 0 a 5%	0,2
De 5 a 10%	0,4
De 10 a 20%	0,7
De 20 a 50%	0,8
Acima de 50%	1,0

Fonte: Bordignon, 2012.

Como estes valores foram arbitrados e o reservatório da PCH não foi devidamente modelado, pode ocorrer um comando inviável da usina na prática. Mas o objetivo deste trabalho não é o controle direto do despacho, e sim sinalizar a probabilidade de ultrapassagem de um determinado valor de demanda com base nas medidas de demanda atual e variáveis climáticas e, com estes valores de probabilidade, auxiliar na elaboração de uma programação de despacho da PCH.

Para testar a viabilidade do agendamento do despacho, foram analisados os dados realizados do mês de dezembro de 2011, quando a demanda medida da supridora ultrapassou o valor contratado nos dias 28 e 30, como mostra a Figura 36.

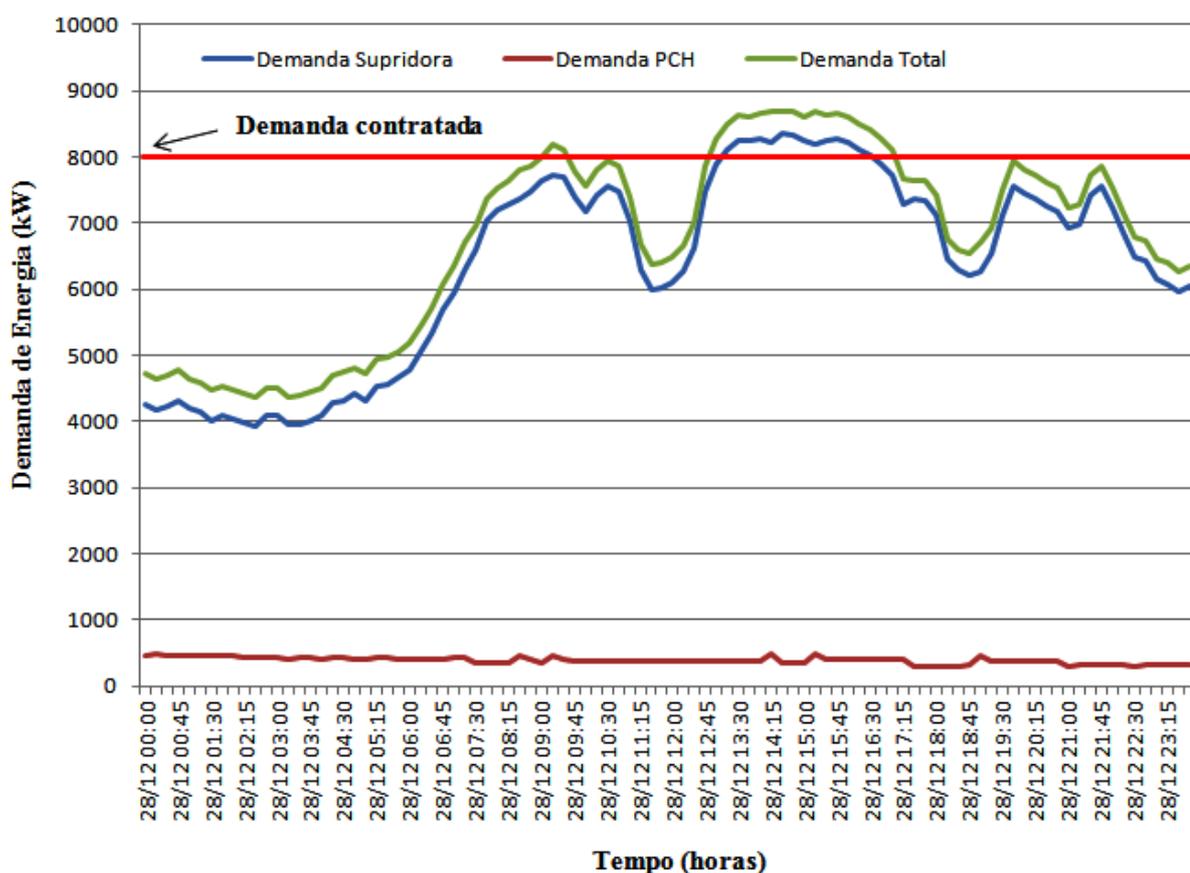
Figura 36 – Demanda realizada da supridora no mês de dez. 2011.



Fonte: Bordignon, 2012.

A Figura 37 mostra o comportamento das demandas da supridora e da PCH para o dia 28 de dezembro. Observa-se que a PCH funcionou continuamente, porém produzindo em torno de 40% da sua capacidade total.

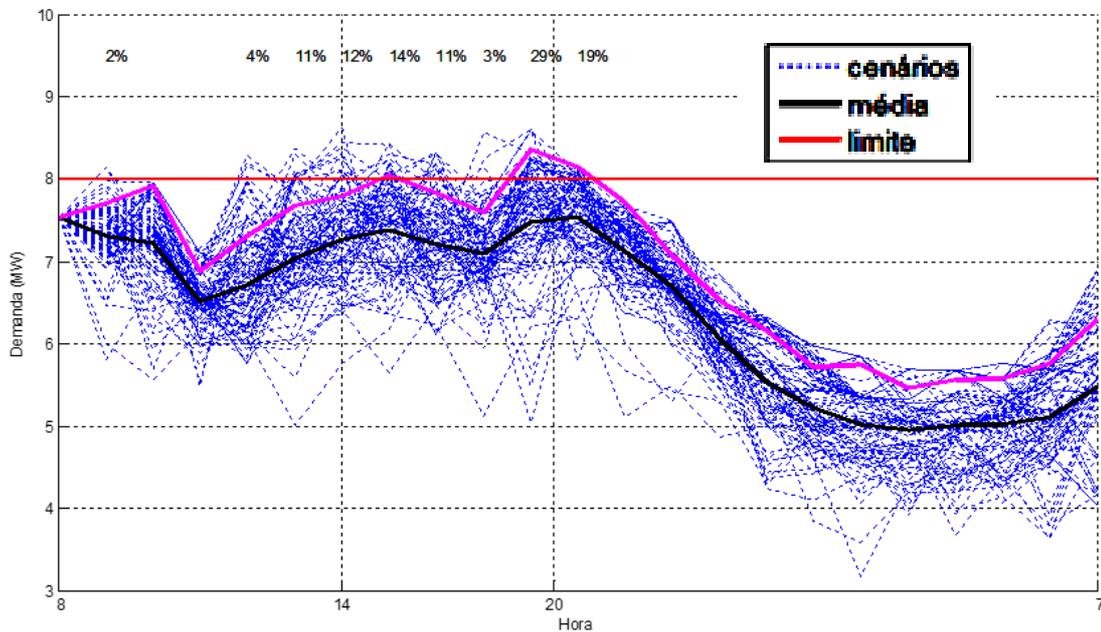
Figura 37 – Demandas realizadas dia 28 de dez.



Fonte: Bordignon, 2012.

Com os valores reais de demanda, temperatura ambiente, umidade relativa do ar e velocidade do vento, para o horário das 08h00min, foi simulada a situação no protótipo do previsor para se obter as probabilidades de ultrapassagem da demanda contratada e os horários em que a mesma iria ocorrer para este dia de dezembro (figura 38).

Figura 38 – Probabilidades de ultrapassagem da demanda no dia 28 de dez.

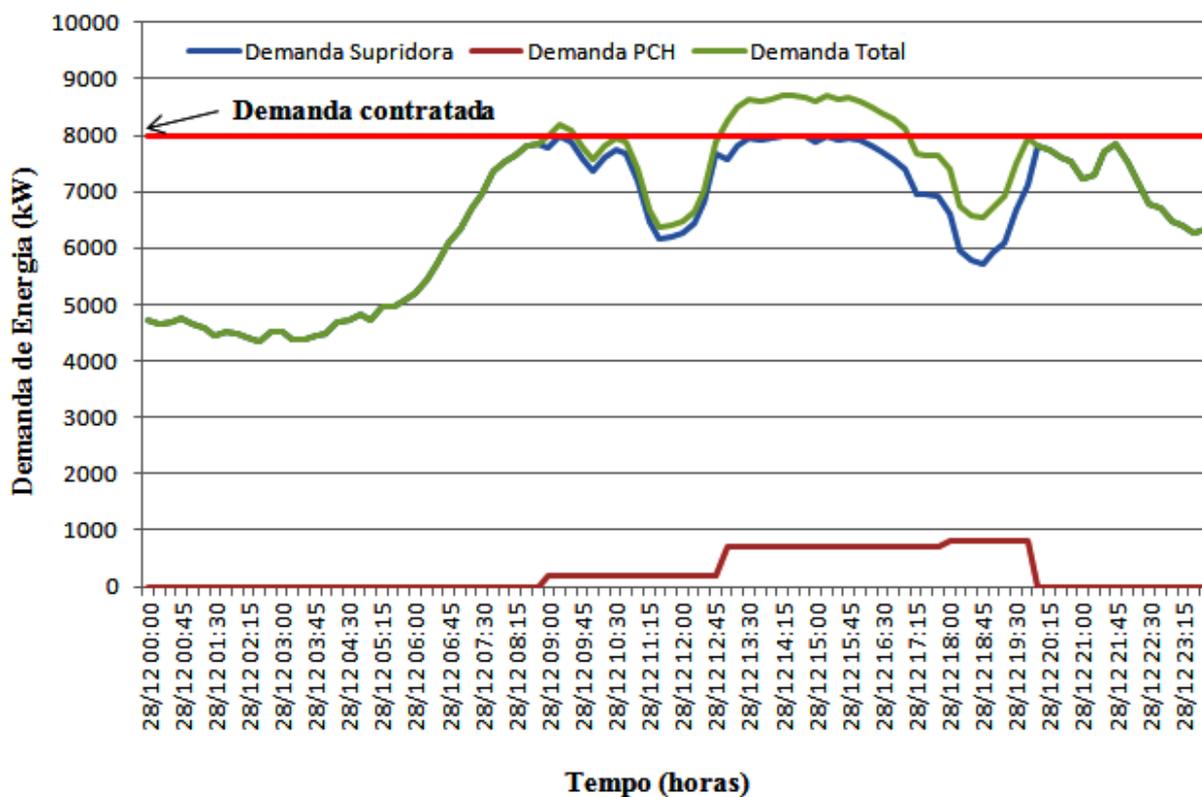


Fonte: Bordignon, 2012.

Aplicando os patamares da tabela 5, para o despacho a PCH, os valores de demanda da supridora ficaram abaixo dos 8,0 MW, portanto sem ultrapassar o valor da demanda contratada. A Figura 39 mostra como ficariam os valores de demanda da supridora, demanda da PCH e demanda total, com o agendamento do despacho para o dia em questão. Já a Figura 40 mostra o comparativo da demanda da supridora sem o agendamento e com o agendamento do despacho da PCH.

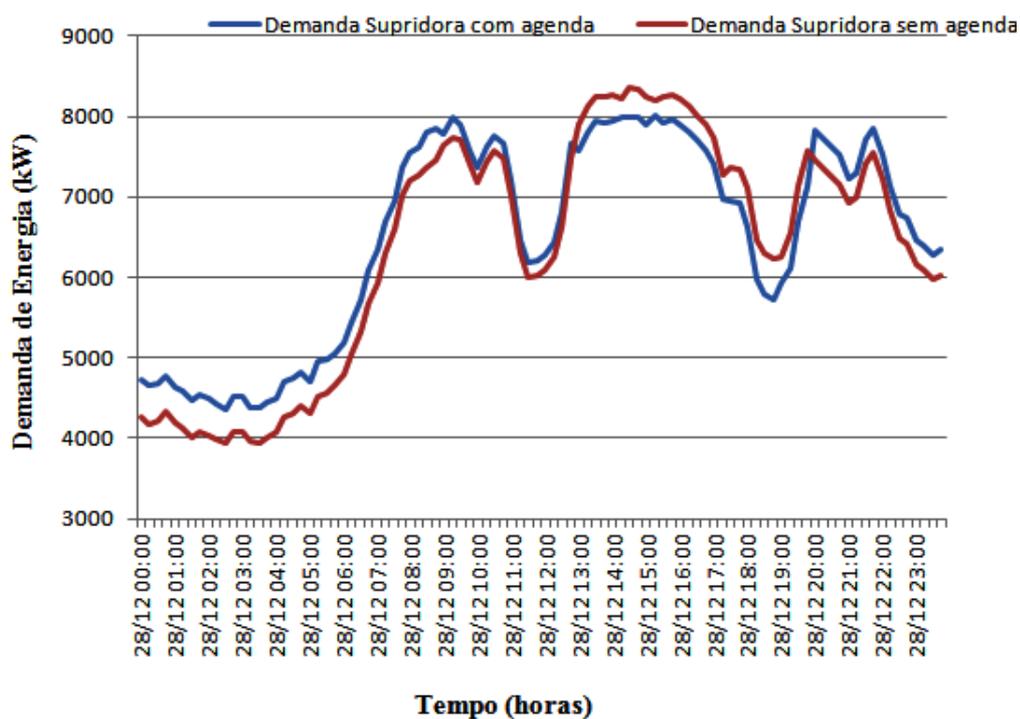
É importante salientar que nesta simulação foi levada em consideração apenas a previsão para o uma determinada hora do dia e que o previsor adapta as previsões de hora em hora, conforme os valores reais de entrada o que, certamente, irá melhorar ainda mais o índice de acerto das previsões e possibilitar uma melhor programação do despacho da PCH.

Figura 39 – Demandas com o agendamento do despacho da PCH.



Fonte: Bordignon, 2012.

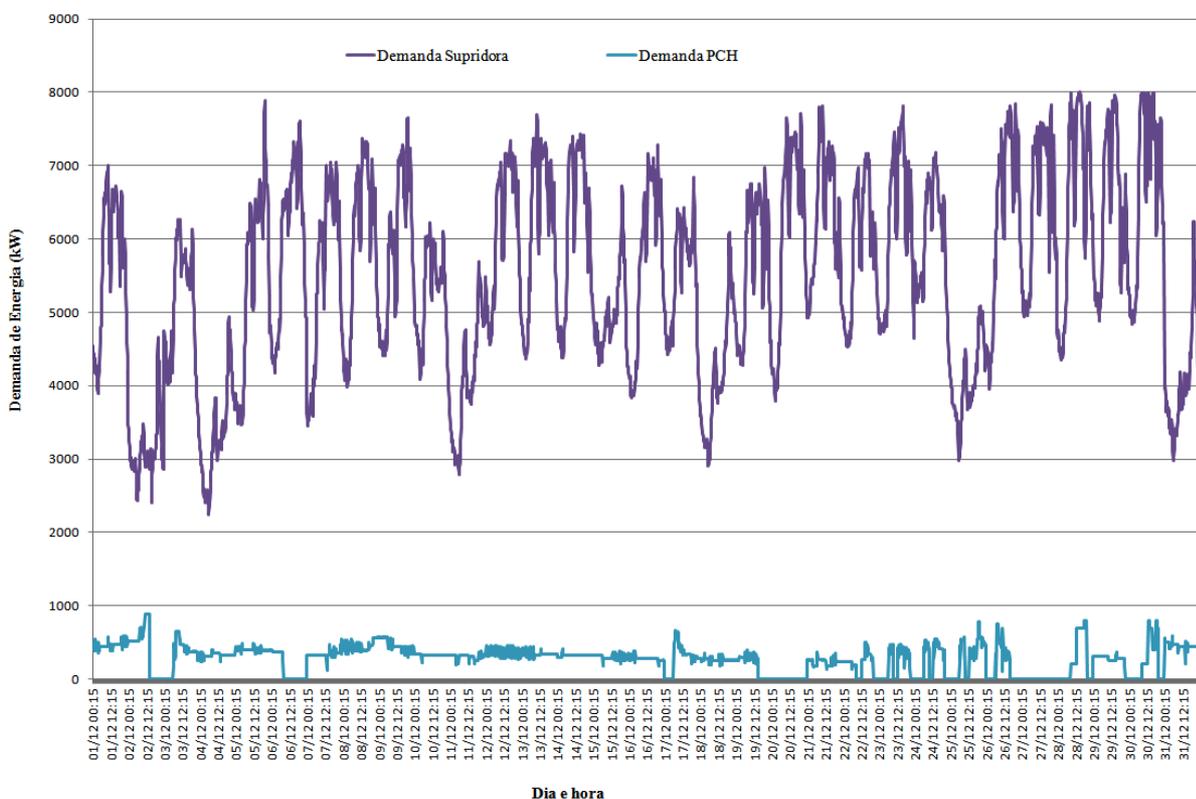
Figura 34 – Comparativo das Demandas com e sem o agendamento do despacho da PCH.



Fonte: Bordignon, 2012.

Realizando a mesma análise para o dia 30 de dezembro, quando também houve a ultrapassagem da demanda contratada da supridora, os resultados foram semelhantes. A Figura 41 mostra como ficaria a demanda da supridora, para o mês de dezembro de 2011, com o agendamento do despacho da PCH, realizado com o auxílio do método predictor de carga desenvolvido.

Figura 35 – Demandas do mês de dezembro após o agendamento do despacho da PCH.



Fonte: Bordignon, 2012.

O agendamento do despacho da PCH foi realizado somente para os dias críticos, porém poderia ser realizado para os demais dias, visando um melhor aproveitamento da água da PCH e aliviando os alimentadores nos momentos de maior exigência.

7 CONCLUSÕES E TRABALHOS FUTUROS

7.1 Conclusões gerais

Inicialmente foi realizada uma revisão da literatura relacionada à previsão de demanda de energia elétrica com o objetivo de obter informações sobre os métodos empregados para realizar a previsão nos distintos horizontes de planejamento. Esta investigação resultou na observação de que poucos são os trabalhos existentes que desenvolveram metodologias de previsão de carga no horizonte de curtíssimo, de minutos ou horas à frente. A maioria dos trabalhos encontrados se concentra na pesquisa em horizontes de curto, médio e longo prazo e são desenvolvidos para sistemas elétricos de grande e médio porte, praticamente inexistindo estudos para pequenos sistemas elétricos.

Neste trabalho foi apresentada metodologia de previsão de carga, no horizonte de curtíssimo prazo, que considera a influência das condições climáticas e que pode ser aplicada em pequenas empresas do setor elétrico de potência, inclusive auxiliando na programação do regime de operação de PCH's. As PCH's são muito importantes economicamente para a maioria das concessionárias, permissionárias e cooperativas de distribuição de energia elétrica, pois geram boa parte da energia fornecida por estas empresas. Já o restante da energia demandada é adquirido de outras distribuidoras de maior porte, através de contratos de fornecimento de energia elétrica com valores de demanda contratada, inclusive com cláusulas de cobrança de adicional por ultrapassagem deste valor contratado.

Em épocas de estiagem, portanto, é muito importante que a PCH esteja funcionando nos momentos em que a demanda atinja os valores máximos. Desta forma se faz extremamente necessária uma eficiente estimativa de valores e horários em que esta demanda máxima irá ocorrer.

A metodologia desenvolvida envolve a criação de um modelo probabilístico discreto (cadeia de Markov) a partir da classificação dos dados históricos em um Mapa Auto-Organizável (SOM). Este método é inovador, pois apresenta como diferencial em relação aos demais métodos existentes, o fato de considerar a influência das variáveis climáticas (temperatura, umidade relativa do ar e velocidade do vento) para a previsão de demanda de energia elétrica no curtíssimo prazo, além de que os valores de entrada de demanda de energia e das variáveis climáticas

(temperatura e umidade relativa do ar) são obtidos em tempo real, através de um sistema SCADA, o que permite que o previsor se ajuste aos novos dados de entrada, de hora em hora, tornando a previsão de demanda mais precisa, e os resultados obtidos permitem elaborar a programação de operação de uma PCH, de forma a garantir o funcionamento da mesma nos momentos mais críticos, de maior demanda do sistema.

Diversos testes foram feitos utilizando um sistema protótipo para simular as previsões de demanda, levando-se em conta os dias atípicos (feriados), dias úteis e finais de semana, nos quais o sistema obteve êxito verificando-se, em sua maior parte dos testes, erros médios abaixo de 5%, o que pode ser considerado como aceitável, se tratando de previsões de carga no horizonte de curtíssimo prazo.

Outro diferencial apresentado pela metodologia desenvolvida é o fornecimento da informação da probabilidade de violação da demanda contratada a partir das previsões de carga. Isso possibilita à empresa definir medidas a serem tomadas com o propósito de evitar a ultrapassagem do valor contratado da demanda como, por exemplo, programar o funcionamento de uma PCH para que a mesma esteja funcionando nos horários críticos. Para comprovar esta funcionalidade, foram realizados testes utilizando os dados reais de uma pequena distribuidora de energia elétrica, do mês de dezembro de 2011, em que houve estiagem, e os resultados comprovaram a eficiência da metodologia.

Desta forma, pode-se afirmar que o sistema desenvolvido neste trabalho, é capaz de realizar previsões de carga, em curtíssimo prazo, com pouca perda na precisão dos resultados e mesmo ocorrendo estas perdas, as mesmas não impossibilitam validar a metodologia desenvolvida como um bom sistema de previsão de cargas, no horizonte de curtíssimo prazo. Da mesma forma, é possível elaborar uma agenda de programação de despacho de uma PCH, com eficiência, com as informações obtidas com previsor de cargas desenvolvido.

7.2 Trabalhos publicados e apresentados em eventos científicos

Os seguintes trabalhos relacionados a essa dissertação foram publicados e ou apresentados em anais de Congressos Científicos, ao longo do desenvolvimento desta pesquisa.

BORDIGNON, S.; BERNARDON, D. P.; SPERANDIO, M.; BORDIN, G.; MARX, W. F.; SILVA, C. V. M. **Elaboração de um Modelo Probabilístico Previsor de Demanda de Energia Elétrica utilizando Cadeia de Markov e Mapas Auto-Organizáveis.** XXIV Congresso Regional de Iniciação Científica e Tecnológica em Engenharia – CRICTE 2010, Rio Grande, RS, 2010.

BORDIGNON, S.; BERNARDON, D. P.; SPERANDIO, M.; BORDIN, G.; MARX, W. F.; SILVA, C. V. M. **Metodologia para Previsão de Demanda de Energia Elétrica em Curtíssimo Prazo baseada em um Modelo Probabilístico Discreto.** I Congresso de Iniciação Científica e Pós Graduação – I CICPG 2010, Florianópolis, SC, 2010.

BORDIGNON, S.; BERNARDON, D. P.; SPERANDIO, M.; BORDIN, G.; GARCIA, V. J.; SILVA, C. V. M. **Construção de um Modelo Probabilístico para Previsão de Demanda a partir de Mapas Auto-Organizáveis.** XXVIII Congresso Brasileiro de Automática – XXVIII CBA 2010, Bonito, MS, 2010.

BORDIGNON, S.; BERNARDON, D. P.; SPERANDIO, M.; BORDIN, G.; GARCIA, V. J.; SILVA, C. V. M.; GOMES, R. R. **Variáveis Climáticas Aplicadas à Previsão de Demanda em Curtíssimo Prazo.** Congresso Internacional de Distribuição de Energia Elétrica – CIDEL 2010, Buenos Aires, Arg, 2010.

BORDIGNON, S.; BERNARDON, D. P.; SPERANDIO, M.; BORDIN, G.; GARCIA, V. J.; SILVA, C. V. M. **Método de Previsão de Demanda para Auxiliar o Despacho de uma Pequena Central Hidrelétrica.** XIX Seminário Nacional de Distribuição de Energia Elétrica – SENDI 2010, São Paulo, SP, 2010.

BORDIGNON, S.; BERNARDON, D. P.; SPERANDIO, M.; BORDIN, G.; GARCIA, V. J. **Desenvolvimento de Algoritmos e Software para Previsão de Carga na Área de Concessão da Mux Energia – Horizonte de Curtíssimo Prazo.** VI Congresso de Inovação Tecnológica em Energia Elétrica – VI CITENEL 2011, Fortaleza, CE, 2011.

BORDIGNON, S.; BERNARDON, D. P.; SPERANDIO, M.; BORDIN, G.; GARCIA, V. J. **Despacho Automático de Pequenas Centrais Hidrelétricas para Otimização do Valor de Demanda Contratada com a Supridora**. IX Simpósio de Automação de Sistemas Elétricos – IX SIMPASE 2011, Curitiba, PR, 2011. Trabalho premiado com o segundo lugar geral no evento.

7.3 Sugestões para Trabalhos Futuros

Os resultados produzidos nesta pesquisa podem ser considerados satisfatórios, conforme argumentado anteriormente. Porém, sugerem-se algumas melhorias e procedimentos que podem ser implementados com o propósito de tornar esta metodologia mais eficiente:

- Aumentar o tamanho dos Mapas Auto-Organizáveis e realizar novo treinamento da Rede Neural, visando maior precisão na previsão de carga;
- Realizar comparações entre o método desenvolvido neste trabalho, com outros métodos de previsão de carga existentes na literatura para verificar o impacto das variações climáticas na assertividade das previsões;
- Aplicar a metodologia desenvolvida neste trabalho, desdobrando a mesma por segmento de mercado, visando ampliar a validade da previsibilidade da previsão;
- Desenvolvimento de um previsor de temperatura e umidade relativa do ar;
- Modelagem matemática da PCH, permitindo realizar previsão de vazão de água, no horizonte de curtíssimo prazo, a fim de possibilitar o planejamento da disponibilidade de funcionamento da usina.
- Desenvolvimento de programas de despacho automático da PCH, em tempo real, a partir da utilização de softwares de simulação e otimização.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABDEL-AAL, R. E. Univariate Modeling and Forecasting of Monthly Energy Demand Time Series Using Abductive and Neural Networks. **Computers & Industrial Engineering**, v. 54, p. 903-917, 2007.
- ALSAYEGH, O. et al. Prediction of the Long-Term Electric Power Demand Under the Influence of A/C Systems. **Journal of Power and Energy**, vol. 221, p. 67-75, 2007.
- ALTRAN, A. B. **Sistema Inteligente para Previsão de Carga Multinodal em Sistemas Elétricos de Potência**. Tese (Doutorado em Engenharia) - Universidade Estadual Paulista – Faculdade de Engenharia, Ilha Solteira, 2010.
- AL-KANDARI, A. M.; SOLIMAN, S. A.; EL-HAWARY, M.E. Fuzzy Short-Term Electric Load Forecasting. **Electrical Power & Energy Systems**, Guildfort. v. 26. n. 2. p. 111-122, 2004.
- ANDRADE, L. C. M. **Abordagem Neurofuzzy para Previsão de Demanda de Energia Elétrica no Curtíssimo Prazo**. Dissertação (Mestrado de Engenharia Elétrica) – Escola de Engenharia de São Carlos – Universidade de São Paulo – Programa de Engenharia Elétrica, São Carlos, 2010.
- BASHIR, Z. A.; EL-HAWARY, M. E. Applying Wavelets to Short-Term Load Forecasting Using PSO-Based Neural Networks. **IEEE Transactions on Power Systems**, v. 24, p. 20-27, 2009.
- BECALLI, M. et al. Forecasting Daily Urban Electric Load Profiles using Artificial Neural Networks. **Energy Conversion and Management**, v. 45, p. 2879-2900, 2004.
- BOURGES, F. **Planejamento da Operação de Pequenas Centrais Hidrelétricas: Enfoque Sistêmico**. Dissertação (Mestrado de Engenharia Elétrica) – Universidade Federal do Paraná – Programa de Pós-graduação em Engenharia Elétrica, Curitiba, 2009.
- BORDIGNON, S. et al. Desenvolvimento de Algoritmos e *Software* para Previsão de Carga na Área de Concessão da Mux Energia – Horizonte de Curtíssimo Prazo. In: CONGRESSO DE INOVAÇÃO TECNOLÓGICA EM ENERGIA ELÉTRICA, 6., 2011, Fortaleza. **Anais...** Fortaleza, 2011.
- BOX, G. E.; JENKINS, G. M. **Times Series Analysis: Forecasting and Control**. San Francisco: Holden-Day, 1976. 575p.
- BOX, G. E.; JENKINS, G. M.; REINSEL, G. **Times Series Analysis: Forecasting and Control**. 3rd. ed. Englewood Clis: Prentice Hall, 1994.
- BRAGA, A. P.; CARVALHO, A. C.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: Livraria Técnica Científica, 2000.
- CAMPOS, J. R. **Desenvolvimento de um Sistema Dinâmico para Predição de Cargas Elétricas por Redes Neurais Através do Paradigma de Programação**

Orientada a Objeto sob a Linguagem JAVA. Dissertação (Mestrado em Engenharia) – Universidade Estadual Paulista – Faculdade de Engenharia, Ilha Solteira, 2010.

CAMPOS, R. J. **Previsão de Séries Temporais com Aplicações a Séries de Consumo de Energia Elétrica.** Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Minas Gerais – Programa de Pós-graduação em Engenharia Elétrica, Belo Horizonte, 2008.

CAVALLARO, F. Electric Load Analysis Using an Artificial Neural Network. **International Journal of Energy Research**, v. 29, p. 377-392, 2005.

CHARYTONIUK, W.; CHEN, M. Very Short-Term Load Forecasting Using Artificial Neural Networks. **IEEE Transactions on Power Systems**, v. 15, p. 263-268, 2000.

COELHO, M. C. S.; AGUIRRE, L. A. Previsão On-line de Carga a Curto Prazo Utilizando Redes NeoFuzzy – Redes Yamakwa. In: SEMINÁRIO DO CENTRO DE PESQUISAS HIDRÁULICAS DA UNIVERSIDADE FEDERAL DE MINAS GERAIS, 2003, Belo Horizonte. **Anais...** Belo Horizonte: UFMG, 2003.

COTTET, R.; SMITH, M. Baysean Modeling and Forecasting of Intraday Electricity Load. **Journal of the American Statistical Association**, vol. 98, p. 839-849, 2003.

DE GOOIJER, J. G.; HYNDMAN, R. J. 25 years of time series forecasting. **International Journal of Forecasting**, USA, v.22, n.3. p.443-473, 2006.

DIAS, E. D. M. **Previsão de Médio Prazo do Consumo de Energia Elétrica no Brasil: Estimação via Metodologia Box & Jenkins e Regressão Dinâmica.** Dissertação (Mestrado em Economia Aplicada) – Universidade Federal de Juiz de Fora – Programa de Pós-graduação em Economia Aplicada, Juiz de Fora, 2008.

ENCINA, A. S. A. **Um Modelo de Otimização do Despacho de Máquinas em Usinas Hidrelétricas.** Dissertação (Mestrado em Engenharia de Sistemas) – Faculdade de Engenharia Elétrica e de Computação- Universidade Estadual de Campinas – Departamento de Engenharia de Sistemas, Campinas, 1999.

ENGLE, R. F.; MUSTAFA, C.; RICE, J. Modeling Peak Electricity Demand. **International Journal of Forecasting**, USA, v. 11, p. 241-251, 1992.

FALCO, G. P. **Técnicas Univariadas Aperfeiçoadas para a Previsão de Curtíssimo Prazo a Partir de Dados Horários.** Dissertação (Mestrado em Engenharia Elétrica) – Departamento de Engenharia Elétrica – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2005.

HAIDA, T.; MUTO, S. Regression Based Peak Load Forecasting using a Transformation Technique. **IEEE Transactions on Power Systems**, v. 9, p. 1788-1794, 1994.

HAYKIN, S. **Redes Neurais: princípios e prática.** 2.ed. Porto Alegre: Bookman, 2001.

HYDE, O.; HODNETT, P. F. An Adaptable Automated Procedure for Short-Term Electricity Load Forecasting. **IEEE Transactions on Power Systems**, v. 12, p. 84-93, 1997.

JANG, J. R. ANFIS: Adaptive-Network-Based Fuzzy Inference System. **IEEE Transactions on Systems, Man, and Cybernetics**, 1993.

KARAYIANNIS, N. B. et al. Evaluation on Cosine Radial Basis Function Neural Networks on Electric Power Load Forecasting. **Proceedings of the International Joint Conference on Neural Networks**, v. 3, p. 2100-2105, 2003.

KARAYIANNIS, N. B. et al. Short-Term Power Load Forecasting Based on Cosine Radial Basis Function Neural Networks: An Experimental Evaluation. **International Journal of Intelligent Systems**, v. 20, p. 591-605, 2005.

KAWAUCHI, S. et al. Development of Very-Short-Term Load Forecasting Based on Chaos Theory. **Electrical Engineering in Japan**, vol. 148, p. 55-63, 2004.

KOHONEN, T. **Self-Organizing Maps**. 3. ed. Springer-Verlag, 2001.

LIU, K. et al. Comparison of Very Short-Term Load Forecasting Techniques. **IEEE Transactions on Power Systems**, v. 11, n. 2, 1996.

MAEDA, J. L. Y.; LOTUFO, A. D. P.; LOPES, M. L. Previsão de cargas elétricas através de uma rede neural de base radial (RBF) utilizando a função GRNN do MATLAB. In: BRAZILIAN CONFERENCE ON DYNAMICS, CONTROL AND APPLICATIONS, 7., 2008, São Paulo. **Anais...** São Paulo: UNESP, 2008.

METHAPRAYOON, K. et al. Multistage Artificial Neural Network Short-Term Load Forecasting Engine With Front-End Weather Forecast. **IEEE Transactions on Industry Applications**, v.43, p. 1410-1416, 2007.

MULLER, G. M. **Despacho de Máquinas e Geração de Usina Hidrelétrica Individualizada Utilizando Algoritmos Genéticos**. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Rio de Janeiro – Programa de Pós-graduação em Engenharia Elétrica, Rio de Janeiro, 2010.

MURTO, P. **Neural Network Models for Short-Term Load Forecasting**. Thesis (Masters) – Department of Engineering Physics and Mathematics, Helsinki University of Technology, Helsinki, 1998.

NOSE FILHO, K.; LOTUFO, A. D. P.; LOPES, M. L. Utilização de Redes Neurais Artificiais e Redes Neuro-Fuzzy para Previsão de Cargas Elétricas. In: BRAZILIAN CONFERENCE ON DYNAMICS, CONTROL AND APPLICATIONS, 7., 2008, São Paulo. **Anais...** São Paulo: UNESP, 2008.

O'DONOVAN, T. M. **Short-Term Forecasting: an Introduction to the Box-Jenkins Approach**. New York: John Wiley & Sons, 1983.

OLIVEIRA, M. O. et al. Projeção de Demanda de Energia Elétrica a Curtíssimo Prazo considerando o Índice de Desconforto. In: SBSE – SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS, 3., 2010, Belém. **Anais...** Belém, PA: UFP, 2010.

PAI, P. F.; HONG, W.C. Forecasting Regional Electricity Load on Recurrent Support Vector Machines with Genetic Algorithms. **Electric Power Systems Research**, v. 74. p. 417-425, 2005.

PAPALEXOPOULOS, A. D.; HESTERBERG, T. C. A Regression-Based Approach to Short-Term Load Forecasting. **IEEE Transactions on Power Systems**, v. 5, p. 1535-1543, 1990.

PAPALEXOPOULOS, A. D.; HAO, S.; PENG, T. M. An Implementation of a Neural Network Based Load Forecasting Model for the EMS. **IEEE Transactions on Power Systems**, v. 9, p. 1956-1962, 1994.

RAHMAN, S.; HAZIM, O. A Generalized Knowledge-Based Short-Term Load Forecasting Technique. **IEEE Transactions on Power Systems**, v. 8, p. 508-514, 1993.

ROCCO, S. M. **Previsão de Demandas para Controle dos Montantes de Uso do Sistema de Transmissão para Distribuidoras de Energia Elétrica**. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Paraná – Programa de Pós-graduação em Engenharia Elétrica, Curitiba, 2008.

ROMERA, E. et al. Forecasting of the Electric Energy Demand Trend and Monthly Fluctuation with Neural Networks. **Computers & Industrial Engineering**. v. 52. p. 336-343, 2007.

ROMERA, E. et al. Monthly Electric Energy Demand Forecasting with Neural Networks. **Energy Conversion and Management**. v. 49. p. 3135-3142, 2008.

RUZIC, S.; VUCKOVIC, A.; NIKOLIC, N. Weather Sensitive Method for Short-Term Load Forecasting in Electric Power Utility of Serbia. **IEEE Transactions on Power Systems**, v. 18, p. 1581-1586, 1998.

SILVA, C. V. M. **Um Método Híbrido-Adaptativo para Previsão de Demanda de Energia Elétrica baseada em Técnicas de Inteligência Artificial**. Trabalho de conclusão do curso de Engenharia Elétrica da Universidade Federal do Pampa, Alegrete, 2011.

SILVA, L. B. **Metodologia para Otimização da Contratação de uma Distribuidora através de Leilões de Energia**. Dissertação (Mestrado em Engenharia Elétrica) – Pontifícia Universidade Católica – Programa de Pós-graduação em Engenharia Elétrica, Rio de Janeiro, 2008.

SPERANDIO M. **Classificação de Conjuntos Consumidores de Energia Elétrica via Mapas Auto-Organizáveis e Estatística Multivariada**. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Santa Catarina – Programa de Pós-graduação em Engenharia Elétrica, Florianópolis, 2004.

- SPERANDIO M. et al. Despacho Automático de Pequenas Centrais Hidrelétricas para Otimização do Valor de Demanda Contratada com a Supridora. In: SIMPASE – SIMPÓSIO DE AUTOMAÇÃO DE SISTEMAS ELÉTRICOS, 9., 2011, Curitiba. **Anais...** Curitiba: Cigri, 2011.
- SUZUKI, O. et al. A Local Demand Forecast by NN Method for Distributed Autonomous Voltage and Reactive Control System. **Electrical Engineering in Japan**, vol. 159, p. 1216-1269, 2007.
- SWARUP, K. S.; SATISH, B. Integrated an Approach to Forecast Load. **IEEE Computer Applications in Power**. New York, v. 15. n. 1. p. 46-51, 2002.
- TAYLOR, J. W. Short-Term Electricity Demand Forecasting using Double Seasonal Exponential Smoothing. **Journal of the Operational Research Society**, v. 54, p. 799-805, 2003.
- TORRES, G. L. et al. Data Mining in Load Forecasting: Na Approach using Fuzzy Techniques. **Power Engineering Society General Meeting**, IEEE, 2006.
- TRIPATHI, M. M. et al. Short-Term Load Forecasting Using Generalized Regression and Probabilistic Neural Networks in the Electricity Market. **The Electricity Journal**, v. 21, p. 24-34, 2008.
- TRUDNOWSKI, D. J. et al. Real-Time Very Short-Term Load Prediction for Power-System Automatic Generation Control. **IEEE Transactions on Control System Technology**, v. 9, p. 254-260, 2001.
- VESANTO, J. SOM Based Data Visualization Methods. **Elsevier Science Intelligent Data Analysis**, v. 3, n.2, p. 111-126, 1999.
- YALCINOZ, T.; EMINOGLU, U. Short Term and Medium Term Power Distribution Load Forecasting by Neural Networks. **Energy Conversion and Management**. **Oxford**. v. 46. n. 10. p. 1393-1405, 2005.
- YANG, H. Y. et al. Fuzzy Neural Very-Short-Term Load Forecasting Based on Chaotic Dynamics Reconstruction. **Chaos Solitions & Fractals**, vol. 29, p. 462-469, 2006.
- ZADEH, L. A. Fuzzy Sets. **Information and Control**, v. 8, p. 338-353, 1965.