

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”**



**FACULDADE DE ENGENHARIA**

**CÂMPUS DE ILHA SOLTEIRA**

**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**ALINE JARDIM AMORIM**

**PREVISÃO DE CARGA MULTINODAL FORMULADA VIA REDE NEURAL  
BASEADA NA TEORIA DA RESSONÂNCIA ADAPTATIVA COM TREINAMENTO  
DIRETO E REVERSO**



Ilha Solteira  
2019

**ALINE JARDIM AMORIM**

**PREVISÃO DE CARGA MULTINODAL FORMULADA VIA REDE NEURAL  
BASEADA NA TEORIA DA RESSONÂNCIA ADAPTATIVA COM TREINAMENTO  
DIRETO E REVERSO**

Tese apresentada à faculdade de Engenharia do Câmpus de Ilha Solteira – UNESP como parte dos requisitos para a obtenção do título de Doutora em Engenharia Elétrica. Especialidade: Automação.

Prof. Dr. Carlos Roberto Minussi  
Orientador

Ilha Solteira  
2019

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

A524p Amorim, Aline Jardim.  
Previsão de carga multinodal formulada via rede neural baseada na Teoria da Ressonância Adaptativa com treinamento direto e reverso / Aline Jardim Amorim. -- Ilha Solteira: [s.n.], 2019  
88 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2019

Orientador: Carlos Roberto Minussi  
Inclui bibliografia

1. Fator de participação global de carga. 2. Previsão multimodal. 3. Rede de neurais artificiais. 4. ARTMAP-Fuzzy. 5. Treinamentos direto e reverso. 6. Ajuste *Pro Rata* das curvas de carga.

*Raiane da Silva Santos*  
Raiane da Silva Santos

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Previsão de Carga Multinodal Formulada Via Rede Neural Baseada na Teoria da Ressonância Adaptativa com Treinamento Direto e Reverso

AUTORA: ALINE JARDIM AMORIM

ORIENTADOR: CARLOS ROBERTO MINUSSI

Aprovada como parte das exigências para obtenção do Título de Doutora em ENGENHARIA ELÉTRICA, área: Automação pela Comissão Examinadora:

  
Prof. Dr. CARLOS ROBERTO MINUSSI  
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

  
Profa. Dra. ANNA DIVA PLASENCIA LOTUFO  
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

  
Profa. Dra. MARA LUCIA MARTINS LOPES  
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira

  
Profa. Dra. FERNANDA CASEÑO LIMA TRINDADE ARIOLI  
Departamento de Sistemas de Energia Elétrica / Universidade Estadual de Campinas - UNICAMP

  
Prof. Dr. JOSÉ GUILHERME MAGALINI SANTOS DECANINI  
Câmpus de Presidente Epitácio / Instituto Federal de São Paulo - IFSP

Ilha Solteira, 05 de julho de 2019

## AGRADECIMENTOS

Primeiramente, agradeço a Deus pela oportunidade de viver até aqui com saúde e com a capacidade para desenvolver esta pesquisa.

Agradeço aos meus pais Izabel e Odorico pela oportunidade e esforço de me proporcionar o estudo; aos meus filhos Júlia e Gabriel por me proporcionar alegria e motivação; ao meu esposo Estelio pelo seu apoio e compreensão; ao meu irmão Alan que me incentivou e apoiou durante essa jornada de pesquisa do doutorado; a todos que contribuíram para a realização desse projeto de vida.

Agradeço ao meu orientador Carlos Roberto Minussi pela oportunidade de aprendizado que me proporcionou; às professoras Mara e Anna Diva pela contribuição para o desenvolvimento desta pesquisa.

Agradeço aos meus amigos e companheiros do laboratório SINTEL: Tatiana, Tânia, Haislan, Monara, Marleide, Carol, Mauro, Thays pelo conhecimento compartilhado, pelas conversas e apoio; agradeço também aos amigos que fiz ao longo dessa jornada de pós-graduação: Renzo, Mariana, Uiliam.

Agradeço aos funcionários da UNESP pela prestação de seus serviços, em especial, ao Deoclécio que, várias vezes, “salvou” meu computador e me proporcionou todo o suporte técnico.

Agradeço à CNPq pelo financiamento do meu trabalho de pesquisa durante o período de doutorado.

"O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001"

Tudo tem o seu tempo determinado, e há tempo para todo  
o propósito debaixo do céu.  
Há tempo de nascer, e tempo de morrer; tempo de plantar,  
e tempo de arrancar o que se plantou;  
Tempo de matar, e tempo de curar; tempo de derrubar, e  
tempo de edificar;  
Tempo de chorar, e tempo de rir; tempo de prantear, e  
tempo de dançar;  
Tempo de espalhar pedras, e tempo de ajuntar pedras;  
tempo de abraçar, e tempo de afastar-se de abraçar;  
Tempo de buscar, e tempo de perder; tempo de guardar, e  
tempo de lançar fora;  
Tempo de rasgar, e tempo de coser; tempo de estar calado,  
e tempo de falar;  
Tempo de amar, e tempo de odiar; tempo de guerra, e  
tempo de paz.

## RESUMO

Nesta pesquisa de doutorado, propõe-se o desenvolvimento de um sistema predictor de carga multinodal, via Redes Neurais Artificiais (RNAs). Trata-se da previsão que envolve vários pontos da rede elétrica, *e.g.*, subestações de sistemas de distribuição, alimentadores, transformadores etc., bem como as barras dos sistemas de transmissão de grande porte. Na literatura especializada, há a prevalência de oferta de propostas visando à previsão da carga total (ou global) correspondente ao somatório de todo o consumo demandado no sistema, considerando-se um horizonte, por exemplo, 24 horas à frente. Nesta pesquisa, dar-se-á ênfase à previsão de carga multinodal. Visando realizar esta previsão, há necessidade de se dispor de um procedimento especializado que produza resultados que atendam os requisitos do setor elétrico (precisão desejada, confiabilidade e rapidez). Estes requisitos são os objetivos desta pesquisa, cujo modelo desenvolvido constitui-se num sistema neural inspirado na arquitetura neural da família ART (*Adaptive Resonance Theory*), mais especificamente, a RNA supervisionada ARTMAP-*Fuzzy*, a qual congrega a teoria da ressonância adaptativa e a teoria dos conjuntos *fuzzy*. O emprego da teoria dos conjuntos *fuzzy* confere, às RNAs da família ART, a aptidão de processar informações analógicas, binárias, assim como combinações dessas informações. A opção por esta RNA é em razão do seu atributo de ser estável e plástica. A estabilidade está associada à capacidade de produzir sempre uma solução. A plasticidade (dotação do treinamento incremental) é uma propriedade pouco observada na maioria das redes neurais disponíveis na literatura técnico-científica. É algo semelhante o que ocorre com os humanos, ou seja, à medida que novas informações são disponibilizadas, tornamos cada vez mais, por hipótese, mais “inteligentes”. Conhecer a carga elétrica, com precisão e com a adequada antecedência, é uma necessidade primordial, ou seja, considera-se que a partir do conhecimento da carga é que são conduzidos os estudos sobre os modos operativos do sistema e as estratégias que devem ser realizadas visando atendê-la de forma contínua, econômica (tanto para as empresas, assim como para os consumidores) e de qualidade (tensão, frequência e forma de ondas adequadas). Neste contexto, são apresentados três tipos de construções dos dados de entrada da RNA com as respectivas simulações (experimentos) com vistas a oferecer alternativas para a previsão multinodal, em especial, contemplando um estudo sobre agregação (junção) de barras especiais do sistema, assim como o emprego da Correção *Pro Rata* (*CPR*) das curvas de cargas. Adicionalmente, será apresentada uma nova formulação (quarta proposta) da RNA ARTMAP-*Fuzzy* dotada de uma forma de treinamento designada “treinamento reverso (TR)”. Trata-se uma proposta “inaugural” que, nos primeiros resultados colhidos, tem-se mostrado promissora. Também, serão apresentados os respectivos resultados das simulações. Visando testar o método proposto, apresenta-se uma aplicação considerando uma base histórica de uma companhia do setor elétrico internacional.

**Palavras-chave:** Fator de participação global de carga. Previsão multimodal. Rede de neurais artificiais. ARTMAP-*Fuzzy*. Treinamentos direto e reverso. Ajuste *Pro Rata* das curvas de carga.

## ABSTRACT

This research proposes to develop a multinodal load forecasting system by Artificial Neural Networks. This is a prediction for several points of the electrical network, e.g. distribution substations, feeders, transformers, etc., as well as busses of huge transmission systems. The literature offers proposals for total load forecasting (or global) corresponding to the sum of all demanded consumption considering a horizon of 24h ahead. This research emphasizes multinodal load forecasting. To perform this prediction, it is necessary to have a specialized procedure that provides results attending the requests of the electrical system (desired precision, reliability and velocity). These requests are the objective of this research, whose developed model is based on ART (Adaptive Resonance Theory) family, specifically the supervised Fuzzy ARTMAP neural network that uses the adaptive resonance theory and fuzzy logic theory. The option of this neural network is due to the attribute to be stable and plastic. The stability is associated to the capacity to produce always a solution. The plasticity (incremental training) is a propriety that is not observed in most of the neural network available on the literature. This is similar to what occurs with humans, as new information comes, the human being is more intelligent. Knowing the electrical load with precision and in advance is a primordial need. The studies about the operational modes of the system and the strategies used to attend continuously, economically (for consumers and providers) and with quality (voltage, frequency and adequate waveforms) are effectuated with the knowledge of the load. This proposal presents three different types of input data for the ANN (Artificial Neural Network) with the respective simulations to provide alternatives for the multinodal forecasting. It is also provided an aggregation study of the special buses as well as the use of a *Pro Rata* correction of the load curves. Besides, a new formulation (fourth proposal) of the Fuzzy ARTMAP ANN called reverse training (TR) is presented. This is a first proposal and according to the first results is promising. The simulation results are presented as well. The data used are from an abroad company.

**Keywords:** Global load participation factor. Multinodal forecasting. Artificial neural network. ARTMAP-*Fuzzy*.



## LISTA DE FIGURAS

Figura 1 - Composição do sistema elétrico de potência .....	23
Figura 2 - Arquitetura da rede ART .....	31
Figura 3 - Representação geométrica das categorias.....	33
Figura 4 - Arquitetura de uma rede ART- <i>Fuzzy</i> .....	34
Figura 5 - Atividade realizada na camada $F_0$ .....	35
Figura 6 - Atividade realizada na camada $F_1$ .....	36
Figura 7 - Atividade realizada na camada $F_2$ .....	36
Figura 8 - Sistema de previsão de carga .....	48
Figura 9 - Fluxograma da segunda proposta de correção .....	50
Figura 10 - Comportamento típico do FPCG .....	52
Figura 11 - Sistema previsor regional .....	55
Figura 12 - Sistema previsor local.....	56
Figura 13 - Comportamento do fator de participação.....	58
Figura 14- Esquema de previsão da metodologia 4.....	59
Figura 15 - Região de Waikato.....	64
Figura 16 - Curva de carga real e prevista da carga global .....	66
Figura 17 - Conjunto de curvas de cargas prevista no método 1.....	68
Figura 18 - Curva de carga prevista das regiões 1,2 e 3.....	71
Figura 19 - Curvas de cargas locais provenientes da segunda metodologia. ....	72
Figura 20 - Curvas de cargas locais provenientes da terceira metodologia.....	74
Figura 21 - Curvas de cargas locais provenientes da quarta metodologia.....	77

## LISTA DE TABELAS

Tabela 1 - Metodologias e suas características.....	45
Tabela 2 - Entradas do sistema previsor local .....	49
Tabela 3 - Parâmetros utilizados no sistema previsor global .....	66
Tabela 4 - MAPE da previsão global.....	67
Tabela 5 - Parâmetros utilizados na rede para cada subestação .....	67
Tabela 6 - MAPE obtido com os métodos 1 e 2.....	68
Tabela 7 - MAPE regional e local obtido com segunda metodologia. ....	70
Tabela 8 - MAPE das subestações obtido com a terceira metodologia.....	74
Tabela 9 - MAPE das cargas locais .....	76

## LISTA DE ABREVIATURAS

RNA	Redes Neurais Artificiais
ART	Teoria da Ressonância Adaptativa ( <i>Adaptive Resonance Theory</i> )
LTM	Memória em Longo Prazo ( <i>Long Term Memory</i> )
STM	Memória em Curto Prazo ( <i>Short Term Memory</i> )
FPCG	Fator de Participação da Carga Global
PCG	Previsor da Carga Global
PCL	Previsor da Carga Local
MAPE	Erro Percentual Absoluto Médio ( <i>Mean Absolute Percentage Error</i> )
SOM	Mapas Auto-organizados ( <i>Self Organizing Maps</i> )
SPR	Sistema Previsor Regional
SEP	Sistema Elétrico de Potência
CPR	Corretor <i>Pro Rata</i>

## LISTA DE SÍMBOLOS

$F_0$	Camada que representa o vetor de entrada
$F_1$	Camada de comparação
$F_2$	Camada de reconhecimento
$F_0^a$	Camada que representa o vetor de entrada para o módulo ARTa
$F_0^b$	Camada que representa o vetor de entrada para o módulo ARTb
$F_1^a$	Camada de comparação para o módulo ARTa
$F_1^b$	Camada de comparação para o módulo ARTb
$F_2^a$	Camada de reconhecimento para o módulo ARTa
$F_2^b$	Camada de reconhecimento para o módulo ARTb
$A$	Entrada de padrões $F_1^a$ em forma de codificação de complemento no módulo ARTa
$B$	Entrada de padrões $F_1^b$ em forma de codificação de complemento no módulo ARTb
$\rho$	Parâmetro de vigilância
$\rho_a$	Parâmetro de vigilância do módulo ARTa
$\rho_b$	Parâmetro de vigilância do módulo ARTb
$\rho_{ab}$	Parâmetro de vigilância do módulo inter-ART
$\beta$	Parâmetro taxa de treinamento
$\varepsilon$	Tolerância de erro
$W$	Matriz de pesos
$W^a$	Matriz de pesos do módulo ARTa
$W^b$	Matriz peso do módulo ARTb
$W^{ab}$	Matriz peso do módulo inter-ART
$\alpha$	Parâmetro de escolha
$T_j$	Função de escolha
$T_j^a$	Função de escolha do módulo ARTa
$T_k^b$	Função de escolha do módulo ARTb
$I_e$	Atividade em $F_0^a$ do módulo ARTa
$I_s$	Atividade em $F_0^b$ do módulo ARTb
$a$	Vetor de entrada do módulo ARTa
$a_{SPR}$	Vetor de entrada do módulo ARTa do sistema previsor regional
$a_{SPL}$	Vetor de entrada do módulo ARTa do sistema previsor local
$a^c$	Complemento do vetor de entrada do módulo ARTa

$\mathbf{b}$	Vetor de entrada do módulo ARTb
$\mathbf{b}_{SPR}$	Vetor de entrada do módulo ARTb do sistema previsor regional
$\mathbf{b}^c$	Complemento do vetor de entrada do módulo ARTb
$\mathbf{W}_J$	Vetor peso ativo no módulo ARTa
$\mathbf{W}_K$	Vetor peso ativo no módulo ARTb
$\mathbf{W}_{JK}^{ab}$	Vetor peso ativo no módulo inter-ART
$K$	Categoria ativa (escolhida) para o módulo ARTb
$J$	Categoria ativa (escolhida) para o módulo ARTa
$M$	Número de vetores de entrada na camada $F_1$
$N$	Dimensão dos vetores de entrada que na camada $F_2$ formam as categorias
$\mathbf{x}$	Vetor de atividade em $F_1$
$\mathbf{x}^a$	Vetor de atividade em $F_1^a$ no módulo ARTa
$\mathbf{x}^b$	Vetor de atividade em $F_1^b$ no módulo ARTb
$\mathbf{y}$	Vetor de atividade em $F_2$
$\mathbf{y}^a$	Vetor de atividade em $F_2^a$ no módulo ARTa
$\mathbf{y}^b$	Vetor de atividade em $F_2^b$ no módulo ARTb

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>14</b>
1.1	MOTIVAÇÕES .....	14
1.2	OBJETIVOS E CONTRIBUIÇÕES .....	16
1.3	ORGANIZAÇÃO DO TEXTO .....	18
<b>2</b>	<b>PRINCIPAIS PESQUISAS CORRELATAS</b> .....	<b>20</b>
<b>3</b>	<b>PREVISÃO DE CARGAS ELÉTRICAS</b> .....	<b>22</b>
3.1	IMPORTÂNCIA DA PREVISÃO DE CARGA ELÉTRICA .....	22
3.2	CLASSIFICAÇÃO DA PREVISÃO DE CARGA ELÉTRICA.....	24
3.3	FATORES QUE INFLUENCIAM A CARGA ELÉTRICA .....	25
3.4	TÉCNICAS DE PREVISÃO DE CARGA ELÉTRICA.....	26
<b>3.4.1</b>	<b>Lógica Fuzzy</b> .....	<b>27</b>
<b>3.4.2</b>	<b>Redes Neurais Artificiais</b> .....	<b>28</b>
3.5	COMENTÁRIOS .....	28
<b>4</b>	<b>TEORIA DA RESSONÂNCIA ADAPTATIVA (ART)</b> .....	<b>29</b>
4.1	REDE NEURAL ART .....	30
4.2	REDE ART-FUZZY .....	33
4.3	REDE NEURAL ARTMAP .....	38
4.4	REDE NEURAL ARTMAP-FUZZY .....	39
4.5	COMENTÁRIOS .....	44
<b>5</b>	<b>METODOLOGIA</b> .....	<b>45</b>
5.1	SISTEMA PREVISOR DE CARGAS LOCAIS COM CORRETOR <i>PRO RATA</i> .....	45
<b>5.1.1</b>	<b>Método 1</b> .....	<b>46</b>
<b>5.1.2</b>	<b>Método 2</b> .....	<b>50</b>
<b>5.1.3</b>	<b>Ajuste e Seleção dos Nós de Interesse</b> .....	<b>51</b>
5.2	SISTEMA PREVISOR REGIONAL .....	53
5.3	SISTEMA PREVISOR LOCAL .....	55
5.4	ARTMAP-FUZZY COM TREINAMENTO REVERSO.....	56
<b>5.4.1</b>	<b>Previsão da Carga Local com Treinamento Reverso</b> .....	<b>58</b>
<b>5.4.2</b>	<b>Processamento de Tempo</b> .....	<b>61</b>
5.5	COMENTÁRIOS .....	62
<b>6</b>	<b>RESULTADOS E DISCUSSÕES</b> .....	<b>64</b>
6.1	RESULTADO DO SISTEMA PREVISOR GLOBAL.....	65

6.1.1	<b>Análise Gráfica das Curvas de Carga Previstas e Reais do SPG .....</b>	<b>66</b>
6.1.2	<b>Análise do MAPE do Sistema Previsor Global.....</b>	<b>67</b>
6.2	<b>RESULTADOS DA PRIMEIRA METODOLOGIA .....</b>	<b>67</b>
6.2.1	<b>Parâmetros Utilizados na RNA ARTMAP-<i>Fuzzy</i> .....</b>	<b>67</b>
6.2.2	<b>Análise do MAPE dos métodos 1 e 2 .....</b>	<b>68</b>
6.2.3	<b>Análise Gráfica das Curvas de Cargas Previstas e Reais dos métodos 1 e 2 .....</b>	<b>68</b>
6.3	<b>RESULTADOS DA SEGUNDA METODOLOGIA .....</b>	<b>70</b>
6.3.1	<b>Análise do MAPE da Segunda Metodologia .....</b>	<b>70</b>
6.3.2	<b>Análise Gráfica das Curvas de Cargas Previstas e Reais da Segunda Metodologia. .....</b>	<b>71</b>
6.4	<b>RESULTADOS DA TERCEIRA METODOLOGIA .....</b>	<b>73</b>
6.4.1	<b>Análise do MAPE Referente à Terceira Metodologia.....</b>	<b>73</b>
6.4.2	<b>Análise Gráfica das Curvas de Cargas Previstas e Reais da Terceira Metodologia. .....</b>	<b>74</b>
6.5	<b>RESULTADOS DA QUARTA METODOLOGIA.....</b>	<b>76</b>
6.5.1	<b>Análise do MAPE da Quarta Metodologia .....</b>	<b>76</b>
6.5.2	<b>Análise Gráfica das Curvas de Cargas Previstas e Reais da Quarta Metodologia ... .....</b>	<b>77</b>
6.6	<b>COMENTÁRIOS .....</b>	<b>79</b>
7	<b>CONCLUSÕES .....</b>	<b>80</b>
7.1	<b>CONSIDERAÇÕES FINAIS .....</b>	<b>80</b>
7.2	<b>SUGESTÕES PARA TRABALHOS FUTUROS .....</b>	<b>82</b>
	<b>REFERÊNCIAS.....</b>	<b>83</b>

# 1 INTRODUÇÃO

## 1.1 MOTIVAÇÕES

Conhecer a carga a ser suprida pelo sistema elétrico, com precisão e com a devida antecedência, constitui-se em uma necessidade primordial para o setor de energia elétrica, pois é a partir do conhecimento prévio da carga é que são tomadas as decisões sobre os modos operativos do sistema, tais como:

- Despacho de capacidade de geração;
- Análise de confiabilidade;
- Plano de manutenção dos geradores;
- Ampliações de plantas geradoras;
- Cálculo do estado do sistema (fluxo de potência);
- Análise da segurança;
- Etc.

Estudo de estratégias para determinar o conhecimento prévio da carga elétrica devem ser implementados visando atendê-la de forma contínua, econômica (tanto para as empresas, assim como para os consumidores) e de qualidade (tensão, frequência e forma de ondas adequadas).

As previsões de carga são de extrema importância para o setor de energia, por isso definir o intervalo de tempo da previsão é primordial para a tomada de decisões, os horizontes de previsão de carga compreendem intervalos de tempo que variam de curto a longo prazo. As previsões de curto prazo, as quais vão de alguns minutos, horas ou dias à frente, contribuem no sentido de antecipar sobre o quanto deve se gerar nesse período de tempo estabelecido para suprir as necessidades de seus consumidores. Já as previsões de longo prazo são necessárias para o planejamento de expansão das plantas de geração e do sistema de transmissão da energia.

As metodologias clássicas encontradas na literatura que foram desenvolvidas para realizar previsões de carga necessitam de uma modelagem prévia das cargas para serem aplicadas posteriormente, tais como: regressão múltipla ou simples, alisamento exponencial, estimação de estado, filtro de Kalman, modelos ARIMA de Box & Jenkins (BOX; JENKINS, 1976; O'DONOVAN, 1983), porém, a maioria das técnicas apresentadas para realizar



previsões de carga com qualidade necessita de informações que, às vezes são inexistentes nos banco de dados, informações dos efeitos atmosféricos, tais como: velocidade do vento, dias nublados, variações de temperatura, e possíveis eventos atípicos: como greve e feriados, são fatores que influenciam no momento de realizar a previsão de carga elétrica.

Outras metodologias foram desenvolvidas no intuito de realizar previsões sem necessidade de se conhecer, *a priori*, a modelagem dos dados de entrada e, ainda, não há a necessidade de ter muitas informações adicionais para realizar esse processo. São conhecidos como sistemas inteligentes. Dentre elas, destacam-se as redes neurais artificiais e a lógica *fuzzy*.

As Redes Neurais Artificiais (RNAs) são concepções, em *software* e/ou *hardware*, baseadas no funcionamento do cérebro humano (HAYKIN, 2008). Em 1943, McCulloch e Pitts (McCULLOCH, PITTS, 1943), propuseram um neurônio artificial baseado em um neurônio humano, o qual é o principal modelo usado na literatura. A partir desse modelo surgiram concepções complexas de RNA, *e.g.*, as RNAs *Perceptron* (HAYKIN, 2008), de Hopfield (HAYKIN, 2008), de Kohonen (KOHONEN, 1987), retropropagação multicamadas (WERBOS, 1974), RNAs da família ART (*Adaptive Resonance Theory*) (CARPENTER; GROSSBERG, 1988), as quais foram desenvolvidas visando oferecer recursos mais eficientes para a resolução de um grande número de problemas de extensas áreas do conhecimento humano (engenharias, medicina, sistemas agrícolas etc.).

A RNA baseada no uso do algoritmo de retropropagação é considerada, pela literatura, um *benchmark* em termo de precisão. Trata-se de um treinamento (aprendizado) supervisionado. É composta por várias camadas de neurônios dispostos em paralelo e possui sua função de ativação contínua. Essa estrutura permite executar tarefas como: reconhecimento de padrões, diagnósticos, previsões entre outras tarefas. Características essas que fizeram esse algoritmo ser muito utilizado no ambiente de previsões. Porém, sua convergência é demasiadamente lenta e, às vezes, não se observa a convergência, em especial quando há a inserção de uma base de dados de entrada muito grande.

Esses sistemas inteligentes, capazes de se adaptarem automaticamente com o tempo, possuem um problema chamado dilema da plasticidade-estabilidade. O dilema da plasticidade-estabilidade surgiu em razão de questionamento de como o sistema pode ser adaptativo mesmo em resposta a eventos significativos e permanecerem estáveis mesmo em resposta a eventos irrelevantes? Como poderia preservar o conhecimento previamente

aprendido e continuar aprendendo novas informações sem perder o conhecimento adquirido previamente?

As redes neurais baseadas na teoria da ressonância adaptativa (família ART) foram desenvolvidas para solucionar esse problema. Tornaram-se, mais recentemente, uma ferramenta de extrema eficácia na realização de classificação, reconhecimento e previsões. Com esta perspectiva, nesta pesquisa de doutorado, serão abordadas metodologias inspiradas no uso de uma arquitetura especial da família ART, mais especificamente, a RNA ARTMAP-*Fuzzy* (CARPENTER; GROSSBERG, 2016).

## 1.2 OBJETIVOS E CONTRIBUIÇÕES

A maior parte das propostas sobre a previsão de carga, encontradas na literatura especializada, destina-se à previsão de carga global correspondente ao somatório de todas as cargas demandadas (SAINI; SONI, 2002; MALKI; KARAYIANNIS; BALASUBRAMANIAN, 2004). Esse modelo de previsão contribui significativamente para o sistema elétrico de potência, ao fornecer informações para tomada de decisões sobre a alocação de recursos, identificação de prioridades, desenvolvimentos de estratégias, planejamento de expansão da capacidade de geração e na minimização de perdas. Contudo, esta previsão não é adequada para a determinação (conhecimento) do estado do sistema, o qual somente é possível se houver à disposição os valores das cargas em cada barra constituinte do sistema. Assim sendo, conhecer o perfil de carga dos consumidores locais para se ter informações mais específicas como a demanda de carga, em intervalos de tempo reduzidos (minutos, ou no máximo 1 hora), permite executar o cálculo relativo à obtenção do estado do sistema e, muito importante, realizar uma série de estudos que são prioritários para garantir uma operação segura, confiável e contínua. Diante da importância de ter o conhecimento do perfil de carga dos consumidores locais, esta pesquisa tem por objetivo apresentar uma metodologia que possa realizar previsões multinodais, *i.e.*, uma previsão considerando vários pontos da rede elétrica (subestações, transformadores, entre outros) com qualidades de resposta e com um tempo de processamento igual ou inferior ao da previsão global.

Para realizar a previsão multinodal, primeiramente, é proposta uma metodologia que utiliza a rede neural ARTMAP-*Fuzzy*. Nesta metodologia, emprega-se, também, o conceito do Fator de Participação da Carga Global (FPCG) (ALTRAN, 2010, NOSE-FILHO *et al.*, 2011) e um corretor das curvas de carga denominado Corretor *Pro Rata* (CPR) (ABREU *et al.*,

2018). A partir desses conceitos, foram desenvolvidas mais duas metodologias que serão descritas no Capítulo 5.

O sistema previsor é composto por duas partes principais: (1) Previsor de Carga Global (PCG); e (2) Previsor de Carga Local (PCL) (composta por  $n$  módulos previsores locais). A partir da execução da PCG, a PCL é concebida usando-se vários módulos paralelos, cada qual sendo responsável pela previsão de carga de cada barra considerada (transformador, alimentador, subestação). Após ser realizada a previsão pelo sistema previsor aplica-se um corretor *Pro Rata* com o propósito de realizar ajustes das curvas de carga e, conseqüentemente, minimizando erro previsional.

Cada parte do processo da previsão multinodal tem as suas vantagens. Primeiramente, destaca-se que a arquitetura ARTMAP-*Fuzzy*, por possuir as propriedades de estabilidade e de plasticidade, proporciona a obtenção de soluções estáveis e “aprender” novos padrões sem perder o conhecimento adquirido previamente. O uso do conceito do FPCG, no contexto da previsão multinodal, oferece a vantagem de se dispor de curvas com variações mais suaves se comparadas ao comportamento da curva de carga de cada barra. Este detalhe, por hipótese, contribui para a redução do erro previsional. O sistema previsor multinodal possui a vantagem de executado de forma paralela contribuindo para que a supracitada previsão seja ultimada efetivamente com tempo de processamento muitíssimo rápido. Finalmente, o emprego do corretor *Pro Rata*, o qual é um algoritmo simples que foi elaborado com o propósito de mitigar o erro da previsão.

Uma metodologia alternativa, denominada ARTMAP-*Fuzzy* Reversa (AMORIM, *et al.*, 2019), está sendo proposta com dois propósitos: (1) reduzir o erro da previsão multinodal e; (2) reduzir o tempo de processamento. Trata-se de uma proposta preambular que tem se mostrado promissora. Evidentemente, há necessidade da realização de uma série de ajustes e intensificar as simulações. Este assunto faz parte, também, da sugestão para pesquisas futuras.

Portanto, a pesquisa proposta visa desenvolver uma arquitetura neural que possui a capacidade de realizar uma previsão de carga multinodal de curto prazo, de forma confiável, rápida e eficaz; e que ao inserir novos padrões de entrada não seja necessário iniciar um novo treinamento e não ocorram problemas de convergência independente do tamanho do banco de dados utilizado, como se tem observado quando são usadas RNAs baseadas em derivadas, por exemplo, a RNA *backpropagation* (retropropagação) (WERBOS, 1974).

### 1.3 ORGANIZAÇÃO DO TEXTO

Este texto está dividido em sete capítulos. Em cada capítulo, é descrito, de forma detalhada, toda metodologia utilizada para a composição desta pesquisa.

**Capítulo 2. Principais Pesquisas Correlatas:** nesse capítulo são apresentados as principais publicações correlacionadas da área de previsão de carga elétrica. São apresentadas, ainda, algumas técnicas encontradas na literatura que realizam previsão de carga, como, por exemplo, lógica *fuzzy*, RNA etc.

**Capítulo 3. Previsão de Cargas Elétricas:** neste capítulo são apresentados os tipos de classificação temporal da previsão de carga elétrica e, também, os fatores que influenciam o perfil da curva de carga.

**Capítulo 4. Teoria da Ressonância Adaptativa:** neste capítulo é realizada a descrição dos principais conceitos da teoria da ressonância adaptativa, enfocando a arquitetura e o algoritmo da rede neural ARTMAP-*Fuzzy* que é uma das principais ferramentas para o desenvolvimento das previsões multinodais.

**Capítulo 5. Metodologia:** no Capítulo 5 são descritas as metodologias propostas nesta pesquisa. A primeira metodologia proposta, além da rede neural ARTMAP-*Fuzzy* descrita no Capítulo 4, é empregado o conceito do FPCG, o sistema predictor composto por seus dois módulos previsores: global e local, assim como o algoritmo *Pro Rata* que via equacionamento de ajustes faz uma correção ao final da previsão da RNA (visando reduzir o erro da previsão multinodal). Uma metodologia alternativa é proposta no intuito de realizar a previsão multinodal, baseia-se em uma alteração na estrutura da rede ARTMAP-*Fuzzy*, no qual o módulo ARTa-*Fuzzy* do predictor global é utilizado como módulo para os previsores locais realizando assim o treinamento somente dos módulos ARTb-*Fuzzy* do predictor local, essa rede modificada é denominada de ARTMAP-*Fuzzy* Reversa.

**Capítulo 6. Resultados e Discussões:** nesse capítulo são apresentados os resultados decorrentes da aplicação das metodologias propostas no quinto capítulo por meio da representação gráfica das curvas de carga elétrica e a análise comparativa baseada na métrica MAPE (PARK *et al.*, 1991), a qual é considerada um *benchmark* na literatura para fins de medida de desempenho em termo de precisão.

**Capítulo 7. Conclusão e Trabalhos Futuros:** nesse capítulo são apresentadas as conclusões sobre as metodologias propostas, seus resultados e a importância dessa ferramenta para o setor de energia elétrica e, também, são apresentadas sugestões de trabalhos posteriores para a expansão da pesquisa.

Ao final, têm-se as referências bibliográficas utilizadas no desenvolvimento desta pesquisa. Logo após as referências, são relacionados os artigos (*full papers*) publicados e submetidos a periódicos e a congressos, ou a eventos similares.

## 2 PRINCIPAIS PESQUISAS CORRELATAS

A maior parte das publicações, disponíveis na literatura especializadas, aborda a previsão de carga total (global) do sistema, ou seja, compreende o somatório de todas as cargas a serem atendidas (PARK *et al.*, 1991). A informação sobre a carga global, por um período, por exemplo, de 24 horas à frente, é importante com vistas à busca de estratégias de atendimento da demanda (despacho da geração, compra de energia etc.). Contudo, para garantir o atendimento com a qualidade pretendida (continuidade, qualidade das grandezas elétricas exigidas pelo setor elétrico) faz necessário realizar uma série de análises envolvendo critérios estáticos (fluxo de potência etc.) e dinâmicos (estudo da estabilidade de ângulo (STOTT, 1979), de tensão (VAN-CUTSEM; VOURNAS, 2007), há a necessidade de conhecer a distribuição das cargas entre as várias barras do sistema. Então, a partir da carga global, essa distribuição por barra, pode ser provida, basicamente de 2 formas: (1) distribuição proporcional considerando-se um fator de participação constante (média referente a um período predeterminado), ou outra heurística qualquer; (2) realizar a previsão da carga em todos os pontos de interesse (barras) do sistema denominada previsão multinodal. O procedimento (1), em geral, é pouco preciso e, por consequência, os resultados auferidos podem ser considerados estimativas com um certo nível de imprecisão. Contudo, deve-se entender, para que a previsão multinodal, deverá ser processada com um tempo não muito superior à previsão global para não inviabilizar a aplicação dos resultados obtidos. É neste sentido, que esta pesquisa será proposta: obtenção de resultados precisos, confiáveis e rápidos.

Nesta pesquisa, então, a previsão de carga será abordada considerando-se a carga total e a multinodal. Neste sentido, as publicações relacionadas nesta análise serão tratadas no contexto de propostas de previsão de carga multinodal. Ressalta-se que em se tratando da previsão de carga multinodal, há um número reduzido de publicações disponíveis na literatura, como destacadas a seguir.

A referência HANDSCHIN; DÖRNEMANN, 1988 tem sido uma das primeiras propostas de abordagem da previsão envolvendo vários nós da rede elétrica, em especial, nos sistemas de distribuição.

Na referência LAMBERT-TORRES *et al.*, 1992 é proposta uma metodologia para a previsão de carga multinodal baseada nos conceitos dos conjuntos *fuzzy* (YOO *et al.*, 2018).

Estes autores apresentaram uma aplicação usando a base de dados da *Hydro-Quebec Power System* (Canadá).

Em Chen *et al.* (1996), os aludidos autores propuseram um método, por RNAs, para a previsão de carga de subestações da *Taiwan Power Company* (Taiwan) com composições destacadas em cargas residenciais, comerciais e industriais. A RNA empregada corresponde a uma arquitetura *feedforward* com treinamento realizado via algoritmo *backpropagation* (WERBOS, 1974).

Na publicação VILLALBA; BELL, 2000, os autores apresentaram um procedimento destinado à previsão de carga de sistemas de distribuição de energia elétrica. Trata-se de um modelo híbrido para a estimação da demanda elétrica, ou seja, são escolhidos, inicialmente, os nós de interesse para posteriormente ser usada uma RNA para a previsão da carga nos barramentos previamente selecionados. É usada uma RNA de Kohonen (treinamento não supervisionado) (KOHONEN, 1987).

Wu *et al.* (2003) propuseram um método para a previsão de carga de sistemas de distribuição baseado no modelo de Grey Box (BOHLIN, 2006). Essa metodologia foi aplicada para a previsão da demanda e o pico de demanda da subestação *Shaheqiao Hejian* (China).

Na referência Salgado *et al.* (2010) foi proposto um procedimento de previsão da carga associada aos barramentos de sistemas elétricos de potência empregando modelos agregados considerados como tendo comportamentos similares e, também, uma RNA *feedforward* com treinamento realizado usando-se o algoritmo *backpropagation* (WERBOS, 1974). O método proposto foi aplicado considerando-se um sistema de 73 barras.

Em NOSE-FILHO *et al.*, 2011 foi apresentado um método para a previsão de carga multinodal baseado na *General Regression Neural Network* (GRNN) (SPECHT, 1991).

Na referência Torkzadeh *et al.* (2014), os autores propuseram uma metodologia visando à previsão de carga de sistemas de distribuição baseado no uso da regressão multilinear (BOX; JENKINS, 1976) e análise de componente principal (PEARSON, 1901) com o propósito de prever o pico da demanda elétrica de uma subestação da cidade de Yazd (Iran).

Na referência Ahmed (2017) foi proposto um método previsor da carga e a frequência de sistemas de distribuição baseado nos conceitos clássicos da análise estatística. Na referência Abreu *et al.*, (2018) foi usada uma RNA ARTMAP-*Fuzzy* para a previsão de carga multinodal (subestações) de um sistema elétrico da Nova Zelândia (CDS, 2010).

### 3 PREVISÃO DE CARGAS ELÉTRICAS

Para realizar a previsão de energia elétrica, faz-se necessário conhecer as informações indispensáveis para tornar a previsão mais precisa. Por esse motivo, nesse capítulo, apresenta-se como o sistema elétrico é composto e como é o funcionamento de cada parte do sistema. Além de conhecer as etapas de funcionamento do sistema elétrico de potência, outra informação importante é a classificação temporal da previsão de carga. Cada horizonte do tempo de previsão influencia nas tomadas de decisões que o operador terá de tomar. Outro tópico que será abordado nesse capítulo são os fatores que influenciam ao realizar a previsão de carga elétrica. Finalmente, são apresentadas algumas técnicas que realizam a previsão de carga elétrica.

#### 3.1 IMPORTÂNCIA DA PREVISÃO DE CARGA ELÉTRICA

A previsão da demanda a ser fornecida para os consumidores é de extrema importância para o setor elétrico. Ao realizar a previsão de carga, pode-se utilizá-la em várias áreas do setor elétrico, como por exemplo: fluxo de potência, geração econômica, planejamento da produção, planejamento da operação, planejamento da tarifa e preços de eletricidade e serviços prestados ao consumidor (HIPPERT *et al.*, 2001).

O mercado fornecedor de energia elétrica possui a responsabilidade de fornecer energia de qualidade e de forma contínua aos seus consumidores. A previsão de demanda de forma eficiente pode fornecer uma ferramenta de grande utilidade para o setor elétrico tomar suas decisões.

Os Sistemas Elétricos de Potência (SEP) possuem a função de fornecer energia elétrica aos seus consumidores com qualidade há qualquer momento do dia. Esses SEP são subdivididos em três partes importantes no processo de fornecimento de energia elétrica:

- **Geração:** é a primeira parte do processo, cuja função é a conversão de alguma forma de energia (hidrelétrica, eólica, solar, nuclear, carvão, marítima, térmica) em energia elétrica.
- **Transmissão:** segunda parte do processo de fornecimento de energia elétrica, cuja responsabilidade é transportar energia elétrica do centro de geração até os centros de distribuição.



- **Distribuição:** terceira parte do processo, a qual tem por objetivo distribuir a energia elétrica, advinda das linhas de transmissão, aos consumidores de pequeno, médio e grande porte.

Na Figura 1 mostra-se a composição do sistema elétrico de potência.

Figura 1 - Composição do sistema elétrico de potência



Fonte: Elaborada pela própria autora.

Esses processos são sequenciais e devem sempre estar em sincronia. A falha de um dos processos produzirá a interrupção do fornecimento de energia elétrica aos seus consumidores. O conceito de carga está relacionado com a potência elétrica absorvida de uma determinada fonte de suprimento. Neste caso, são identificados vários tipos de carga:

- **Carga de uma Subestação:** é considerada a potência fornecida aos alimentadores;
- **Carga de uma linha de distribuição:** é considerada a potência absorvida por todos os transformadores;
- **Carga de um transformador:** é considerada a potência absorvida pelos consumidores ligados a esse transformador;
- **Carga de um consumidor:** é considerada a potência absorvida pelos aparelhos elétricos, lâmpadas, motores. Os consumidores finais estão divididos em três categorias: industriais, comerciais e residenciais.

A demanda de carga elétrica não possui um valor fixo. Ela possui uma variação entre um valor máximo e um valor mínimo no decorrer do dia. O SEP deverá estar preparado para suprir a demanda requisitada. Para tanto, faz-se necessário realizar um estudo prévio da demanda de energia elétrica envolvendo a análise dos fatores que influenciam o comportamento da carga. Estudos encontrados na literatura têm proposto vários métodos que realizam previsões de demanda de carga elétrica com certo grau de confiabilidade. Esses métodos são classificados em três seguimentos (O'DONOVAN, 1983):

- **Métodos Intuitivos:** são os métodos de previsão que não utilizam modelo matemático formal para descrever a curva de carga.
- **Métodos Autônomos:** são modelos baseados na extrapolação de observações passadas da carga em que é analisada a evolução da carga no tempo, de acordo com

determinados padrões de comportamento. Esses métodos são classificados, como: (1) horizontal; (2) tendencioso; (3) cíclico e (4) sazonal. No padrão horizontal, os dados de carga flutuam em torno de um determinado valor médio constante no tempo. No padrão tendencioso, os dados flutuam em torno de uma curva de tendência. No padrão cíclico, as flutuações ocorrem variando em amplitude e em duração. No caso do padrão sazonal, a carga é influenciada por fatores temporais, tais como: dias da semana, estações do ano etc.

- **Métodos Causais:** esses métodos assumem que o comportamento da carga é descrito por uma ou mais variáveis independentes. Como, por exemplo, a variável utilizada para justificar a tendência de crescimento da carga são os índices socioeconômicos, crescimento populacional.

Para a escolha do método adequado, é necessário determinar o padrão de comportamento da carga, ou seja, a evolução da carga no tempo. Para isso, existe duas classes de série temporal encontrada na literatura (O'DONOVAN, 1983):

- **Estacionária:** quando os dados de carga flutuam em torno de uma média constante no tempo.
- **Não estacionária:** ao contrário da série temporal estacionária, os dados variam com o tempo, ou seja, a série histórica dos dados apresentam padrões tendenciosos, cíclicos, sazonais ou aleatórios.

### 3.2 CLASSIFICAÇÃO DA PREVISÃO DE CARGA ELÉTRICA

A previsão de carga serve como guia para tomadas de decisões. O planejamento e o direcionamento do setor elétrico dependem da identificação e de uma previsão correta da demanda de energia elétrica a serem fornecidas aos seus consumidores. As tomadas de decisões podem ser imediatas em questão de minutos ou horas. Já o planejamento, seja de expansão ou manutenção do sistema de potência pode ser por meses ou anos. Por isso, há uma classificação dos períodos de previsão. Esses períodos são classificados em quatro tipos (MURTO, 1998; METAXIOTIS *et al.*, 2003):

- *Curtíssimo prazo:* ocorre em frações de segundo e, no máximo, em 15 minutos. Nesse caso, são previsões utilizadas para o planejamento de produção *on-line*.
- *Curto prazo:* o período de previsão em curto prazo abrange intervalos de tempo de meia hora a poucas horas, ou até mesmo um dia, ou uma semana. Esse intervalo de

tempo é muito utilizado para previsões operacionais, econômicas e de segurança diária do sistema elétrico de potência.

- *Médio prazo:* seu período de abrangência é de poucas semanas até alguns anos. É utilizado para prever programas de manutenção e planejamento da produção em médio prazo.
- *Longo prazo:* essa previsão envolve um período de 10 a 20 anos. É muito utilizada para um planejamento em longo prazo, como por exemplo, na expansão do sistema elétrico de potência, ou no preço do fornecimento da energia elétrica, ou, ainda, na manutenção de equipamentos.

Dentre todos esses tipos de classificação na previsão de energia, nesta pesquisa, será enfocada a previsão de carga em curto prazo utilizando o período de 24 horas à frente.

### 3.3 FATORES QUE INFLUENCIAM A CARGA ELÉTRICA

O sistema elétrico de potência fornece energia elétrica para seus consumidores. Esses consumidores estão divididos em três classes:

- **Residencial:** a demanda de carga de um consumidor residencial é composta, tipicamente, por seus aparelhos que consomem energia elétrica, tais como: TV, refrigerador, computador, lâmpada, ar-condicionado, chuveiro elétrico.
- **Comercial:** já a demanda de carga do consumidor comercial, é composta por aparelhos que demandam o consumo de energia, como, por exemplo, lâmpada, ar-condicionado, freezer, geladeira etc.
- **Industrial:** o consumidor industrial geralmente possui motores que demandam um consumo maior de energia para o seu funcionamento.

Cada um desses consumidores influencia no comportamento da carga elétrica. Cada um com sua particularidade. Por exemplo, os consumidores residenciais possuem comportamentos particulares, em cada residência, e são os mais difíceis de determinar o comportamento por vários fatores, hábitos diferentes, poder socioeconômico, demográficos, quantidade de pessoas que residem no mesmo local, entre outras situações.

Os consumidores industriais, apesar de serem previsíveis pelo seu histórico de produção, podem ocorrer eventos inesperados como greves, máquinas que necessitam de manutenção, eventos inesperados que possam causar distúrbios no sistema. Comportamentos como esses podem afetar a previsão de carga, pois as indústrias consomem grande parte da eletricidade gerada pelo sistema.

Além desses eventos inesperados existem outros fatores que interferem ao realizar uma previsão de demanda de energia elétrica, tem-se, por exemplo:

- *Fatores climáticos:* são fatores advindos da natureza e ocorrem em curto prazo. Exemplos: velocidade, umidade relativa do ar, chuva, temporais com relâmpagos e trovões, neblina, temperatura. Dentre estes fatores mencionados a temperatura é um dos fatores que mais influencia para o aumento do consumo de energia elétrica, por causa da demanda do consumo de ar-condicionado, refrigerador ou aquecedor e chuveiro elétrico (SWARUP; SATISH, 2002);
- *Fatores econômicos e demográficos:* esses são fatores que ocorrem em longo prazo. A densidade demográfica que é a quantidade de habitante por metro quadrado e o poder econômico de certa região são informações importantes que determinam a evolução da demanda de carga (MURTO, 1998).
- *Fator tempo:* o fator tempo desempenha um papel essencial do ponto de vista da previsão. O fator tempo está dividido em comportamento cíclico e sazonal. O comportamento cíclico que acontece com periodicidade como, por exemplo, a redução significativa da demanda de carga aos sábados e domingos. Já o comportamento sazonal refere-se ao que é temporário, ou seja, o que é típico de determinada época do ano como, por exemplo, natal, ano novo, férias (MURTO, 1998).
- *Fatores esporádicos:* são fatores que ocorrem eventualmente e que causam perturbações na carga, tais como: eventos esportivos (copa do mundo, olimpíadas). Os fatores esporádicos ocasionados pelos consumidores residenciais não influenciam tanto na previsão de demanda de energia. Porém, a paralisação das indústrias pode ocasionar distúrbio muito grande na previsão de demanda (MURTO, 1998).

### 3.4 TÉCNICAS DE PREVISÃO DE CARGA ELÉTRICA

No intuito de realizar a previsão de cargas elétricas, várias técnicas foram desenvolvidas. Elas são classificadas em duas classes (GROSS; GALIANA, 1987):

- *Modelos não dinâmicos (ou estáticos):* a carga é expressa como uma série temporal discreta composta de valores previstos para cada hora durante um período;
- *Modelos dinâmicos:* a carga é identificada não apenas como uma função de tempo do dia, mas também de seus comportamentos mais recentes, ou seja, os valores das saídas dependem dos valores passados das entradas.

Os métodos estão divididos em duas classes: os métodos estatísticos e os sistemas especialistas.

- *Métodos Estatísticos*: são metodologias baseadas em técnicas estatísticas, nas quais há uma modelagem da carga. Estas metodologias são: regressão linear ou múltipla (MURTO, 1998), alisamento exponencial, filtro de Kalman (MOGHRAM; RAHMAN, 1989), espaço de estado e série temporal de Box-Jenkins (O' DONOVAN, 1983).
- *Sistemas Especialistas*: são baseados no conhecimento construído principalmente com as regras que reproduzem o conhecimento, ou seja, são baseados na inteligência artificial capaz de reproduzir o raciocínio humano.

Para realizar uma previsão de carga, é necessário dispor de uma base histórica de dados que contenha o máximo de informações possíveis e que permita realizar uma previsão precisa. Essas informações são: dia da semana, hora, temperatura, fator econômico e social etc. O sistema especialista é uma automatização desse processo de busca. Neste caso, tem-se, por exemplo, a lógica *fuzzy* e as redes neurais artificiais.

### 3.4.1 Lógica Fuzzy

A partir da disponibilidade de uma base de conhecimento adquirida é possível construir um sistema que realize a previsão da demanda de energia elétrica. Esse sistema é representado por meio do uso de regras e de fatos. As regras definem relações entre os fatores externos e as cargas diárias que são desenvolvidas utilizando a teoria da lógica *fuzzy*, que é uma técnica desenvolvida por Zadeh em 1965 (ZADEH, 1965).

A lógica *fuzzy* se difere da lógica tradicional por suas características e detalhes. Ela é uma lógica de multivalores que permitem valores intermediários entre os convencionais sim ou não, verdadeiro ou falso da lógica booleana. Esses valores são chamados de variáveis linguísticas. Essas variáveis *fuzzy* são adjetivos utilizados para modificar a variável de tal forma que os adjetivos *pouco*, *muito*, *morno*, *frio*, *quente*, são formulados matematicamente e processados pelo computador (ZADEH, 1965).

A lógica *fuzzy* possui inúmeras áreas de aplicações. Dentre elas destacam-se as referências de: (AL-KANDARI *et al.*, 2004; LIAO; TSAO, 2004; LIU *et al.*, 1996). Outro sistema especialista são as redes neurais artificiais.

### 3.4.2 Redes Neurais Artificiais

Em 1943, os pesquisadores McCulloch e Pitts (McCULLOCH; PITTS, 1943) desenvolveram um neurônio artificial baseado em um neurônio biológico. Essa proposta foi o início para pesquisas nessa área de Redes Neurais Artificiais – RNA. Em 1949, o pesquisador Donald Hebb publicou um livro intitulado “*The Organization of Behavior*” e introduziu o conceito básico da regra de aprendizado de Hebb (HEBB, 1949).

Já em 1958, Von Neumann descreveu o cérebro em seu livro “*The Computer and the Brain*” (VON NEUMANN, 1958) no qual o cérebro é modelado por meio de *hardware*. Muitos outros pesquisadores continuaram a desenvolver pesquisas inspiradas no neurônio biológico.

Em 1962, Rosenblatt publicou em seu livro “*Principles of Neurodynamics*” (ROSENBLATT, 1962) o conceito de RNA denominadas *perceptron*. Sua capacidade de reconhecer padrões simples despertou muito interesse de outros pesquisadores, mas Minsky & Papert (1969) descobriram que o modelo *perceptron* desenvolvido por Rosenblatt não resolvia problemas do tipo ou-exclusivo. Por esse motivo pararam as pesquisas nessa linha. Em 1969, Minsky propôs uma RNA baseada em reforço com formas simples de aprendizado.

Já no final década de 70 e início da década de 80 começaram a retomar as pesquisas na área de RNA. Em 1973, Von der Malsburg apresentou a primeira RNA de mapa de características auto-organizável. Essa proposta de Von der Malsburg influenciou trabalhos posteriores como o de Teuvo Kohonen (KOHONEN, T, 1987), que desenvolveu os mapas auto-organizados (*Self-Organizing Maps*, SOM). O trabalho de Kohonen serviu como base para o trabalho de Gail Carpenter e Steven Grossberg que desenvolveram a Teoria da Ressonância Adaptativa (ART).

### 3.5 COMENTÁRIOS

Neste capítulo, foi relatada a importância da realização da previsão de carga elétrica e apresentou os fatores que podem influenciar na realização da previsão. Também foram abordados os diferentes tipos de classificação temporal de previsão (curtíssimo prazo, curto prazo, médio prazo, longo prazo) e, também, foram relatadas as técnicas encontradas na literatura que são utilizadas para realizar previsão de carga elétrica.

## 4 TEORIA DA RESSONÂNCIA ADAPTATIVA (ART)

Um problema enfrentado na maioria dos sistemas inteligentes, os quais são capazes de se adaptarem autonomamente, em tempo real e em resposta a eventos inesperados, é o dilema da plasticidade-estabilidade (capacidade de aprender novos padrões sem perder o conhecimento prévio e permanecer estável mesmo com entradas irrelevantes). Na busca de solucionar esse problema, em 1976 Grossberg (GROSSBERG, 1976) introduziu a rede neural nominada *Adaptive Resonance Theory* (ART), cujo sistema possui uma aprendizagem não supervisionada, baseada na teoria do processo de informação cognitiva humana.

Os modelos ART surgiram de uma análise de um tipo mais simples de rede de reconhecimento de padrões adaptativas chamado de aprendizagem competitiva (CARPENTER; GROSSBERG, 1988). A partir da primeira arquitetura de rede ART, foram desenvolvidas outros modelos que fazem parte da família ART (ou ART descendentes):

- **Rede neural ART1:** A rede ART1 foi a primeira RNA desenvolvida da família ART, baseada a partir da *Grossberg Network* (GN). Sua aprendizagem é não supervisionada e as entradas são apenas de padrões binários. A rede ART1 é composta por um conjunto de equações que implementam as propriedades de estabilidade-plasticidade (CARPENTER; GROSSBERG, 1988).
- **Rede neural ART2:** essa rede possui a capacidade de reconhecer tanto padrões binários, quanto padrões analógicos. A execução fase de treinamento é do modo não supervisionado. Possui um mecanismo de normalização dos dados evitando a proliferação de categorias e proporcionando a capacidade de eliminação de ruídos (CARPENTER; GROSSBERG, 1988).
- **Rede neural ART-Fuzzy:** é vista como a evolução da rede ART1, pois ela possui a capacidade de categorizar padrões de entrada analógicos compreendidos entre 0 e 1. O treinamento da rede *ART-Fuzzy* é não supervisionado, e na sua arquitetura inclui os cálculos baseados na lógica *fuzzy* (CARPENTER, GROSSBERG, ROSEN, 1991b).
- **Rede neural ARTMAP:** o treinamento dessa rede é supervisionado. A composição da arquitetura da ARTMAP é formada por dois módulos ART interconectados por um módulo Inter-ART. Essa rede também é capaz de reconhecer os padrões de entradas binários e analógicos. Essa arquitetura foi especialmente desenvolvida para o trato de mapeamentos funcionais (daí a designação “MAP” de mapeamento), ou seja, visando

“elaborar” a modelagem de funções vetoriais:  $\mathbf{y} = \mathbf{f}(\mathbf{x})$ , sendo que  $\mathbf{x}$  e  $\mathbf{y}$  são vetores de entrada e de saída da RNA, respectivamente. A função vetorial  $\mathbf{f}$  (via de regra, é não linear, caótica etc.) é desconhecida que, ao final da fase denominada treinamento (ou aprendizado), ter-se-á concluído o seu modelo. Ressalta-se que essa RNA oferece um grande espectro de aplicações, ou seja, constitui-se num recurso de alta versatilidade de modelagem requerida. A qualidade dos resultados esperados é dependente do conhecimento da sua estrutura interna. Um bom projeto só é consagrado em razão da expertise do usuário (CARPENTER; GROSSBERG; REYNOLDS, 1991a).

- **Rede neural ARTMAP-Fuzzy:** A arquitetura dessa rede é similar à RNA ARTMAP, porém os dois módulos são compostos pela rede ART-Fuzzy, ou seja, os cálculos são baseados na teoria da lógica *fuzzy*. O treinamento dessa rede é, também é realizado de forma supervisionada (CARPENTER *et al.*, 1992).

A composição da família ART é bastante extensa. São disponibilizadas outras RNA para as mais variadas aplicações, como, por exemplo: ARTMAP-Euclidiana (CARPENTER, ROSS, 1995), ARTMAP Gaussiana (WILLIAMSON, 1996) etc. Contudo, nesta pesquisa, limita-se ao sistema ARTMAP-Fuzzy que compreende a essência e o objeto da metodologia proposta.

#### 4.1 REDE NEURAL ART

A arquitetura da rede da família ART é dividida em dois subsistemas, sendo: subsistema de atenção e o subsistema de orientação. O subsistema de atenção possui três camadas: as camadas  $F_0$ ,  $F_1$  e  $F_2$ .

- **Subsistema de Atenção**

Composto por duas camadas de neurônios interconectadas: sendo o campo  $F_1$  a camada que realiza a comparação e o campo  $F_2$  a camada que realiza o reconhecimento, após ser apresentado o vetor de entrada atual no campo  $F_0$ . O subsistema de atenção, na sua primeira camada de neurônios, gera um padrão de ativação de memória de curto prazo (*Short - Term Memory – STM*), pois existe apenas em associação com uma única aplicação de vetor de entrada. Nós ativos, em  $F_1$ , emitem sinal para  $F_2$  via de conexões recorrentes *feedforward* e quando o sinal é de  $F_2$  para  $F_1$  tem-se as conexões recorrentes *feedback*. Nessas conexões, existem pesos associados que são responsáveis pela memória de longo prazo (*Long – Term*



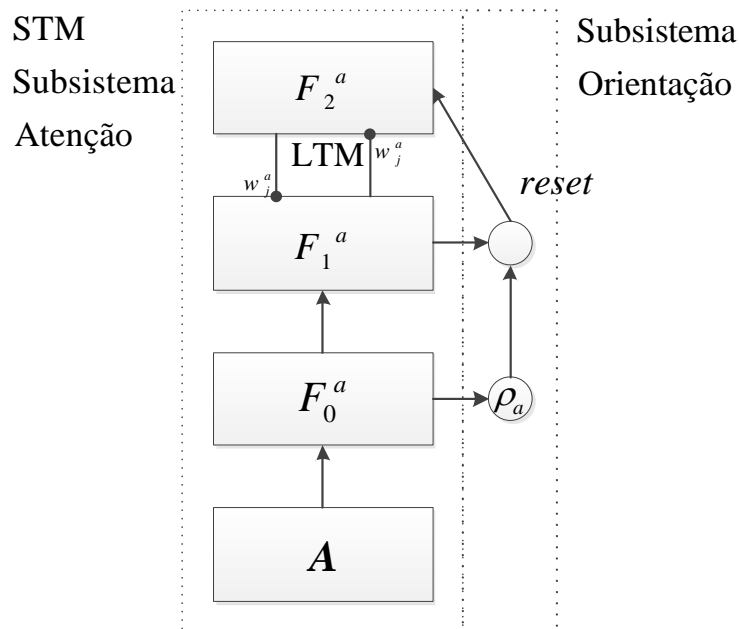
*Memory* – LTM), pois codificam informações que permanecem como parte da rede por um longo período (KEYVAN *et al.*, 1999).

- **Subsistema de Orientação**

O subsistema de orientação possui dois sinais de entrada: um advindo do campo  $F_0$  e o outro é procedente das atividades do campo  $F_1$  que produz um sinal de saída que se conecta com o campo  $F_2$  em resposta ao sinal de *reset*. O *reset* e a ressonância são realizados no subsistema de orientação por meio de um parâmetro de vigilância  $\rho$ . O parâmetro de vigilância  $\rho$  pode ter qualquer valor compreendido entre 0 e 1. É responsável por indicar o grau de discriminação que o sistema deve ter entre as diferentes classes de padrões de entrada, ou seja, ele possui a decisão no processo de classificação de categorias. Essa característica do subsistema de orientação faz com que haja uma estabilização entre o processo STM e a aprendizagem LTM, permitindo que a rede aprenda a novos padrões de entrada sem esquecer o conhecimento prévio (KEYVAN *et al.*, 1999).

Na Figura 2 - ilustra-se a arquitetura básica da rede ART.

Figura 2 - Arquitetura da rede ART



Fonte: Adaptado de Lopes (2005)

- **Parâmetros Importantes**

Os parâmetros utilizados nas redes da família ART são muito importantes para controlar o processo de aprendizagem durante o treinamento da RNA. Esses parâmetros são responsáveis pela estabilização e plasticidade da rede da família ART.

- **Parâmetro de escolha  $\alpha$  ( $\alpha > 0$ ):** o parâmetro  $\alpha$  é considerado um parâmetro de “limite conservador”, pois é responsável por controlar como irá prosseguir a busca antes de selecionar um nó não confirmado. Quando  $\alpha$  é pequeno e uma entrada é apresentada, há a verificação se já existe uma categoria cujo vetor de ponderação seja um subconjunto (dentro de certo grau de similaridade) dessa entrada. Caso houver, essa entrada será selecionada. Isso faz com que os pesos aprendidos sejam conservados sempre que possível. Conforme ocorre a estabilização do processo de aprendizado, as entrada conseguem acessar suas respectivas categorias sem a necessidade de haver uma pesquisa (KEYVAN *et al.*, 1999). Realizando uma análise geométrica, tem-se que ao apresentar uma entrada à rede e essa entrada pertença a mais de um hiper-retângulo o parâmetro de escolha é responsável por assegurar que seja escolhido o menor hiper-retângulo dentre os demais. Ressalta-se que o conceito de hiper-retângulo refere-se ao uso da norma-1, como será instrumentalizada à frente, durante à exposição algorítmica das RNA usadas nesta pesquisa.
- **Parâmetro de vigilância  $\rho$  ( $\rho \in [0,1]$ ):** o parâmetro de vigilância é um dos principais parâmetros das redes da família ART. Ele é responsável por determinar se o padrão de entrada, apresentado à rede, é similar a uma classe já criada. O parâmetro  $\rho$  define critérios para correspondências sob as mesmas condições: se o valor de  $\rho$  for pequeno, tem-se uma capacidade maior de generalização, no entanto poucas classes irão ser criadas. Por outro lado, se o valor de  $\rho$  for grande sua capacidade de generalização é menor, conseqüentemente, haverá a criação de várias classes (KEYVAN *et al.*, 1999).

- **Representação Geométrica**

A rede ART agrupa os padrões de entrada em categorias em forma de hiper-retângulos. Os hiper-retângulos são definidos entre valores *Min* e *Max*. (CARPENTER, GROSSBERG, 1992). Por exemplo, na Figura 3 tem-se os vetores  $\mathbf{u} = [u_1 \ u_2]$  e  $\mathbf{v} = [v_1 \ v_2]$ . Os operadores  $\wedge$  e  $\vee$ , correspondentes aos operadores lógicos *AND* e *OR*, respectivamente (CARPENTER; GROSSBERG, 1992).

$$(\mathbf{u} \wedge \mathbf{v})_1 = \min(u_1, v_1)$$


$$(\mathbf{u} \wedge \mathbf{v})_2 = \min(u_2, v_2)$$

$$(\mathbf{u} \vee \mathbf{v})_1 = \max(u_1, v_1)$$

$$(\mathbf{u} \vee \mathbf{v})_2 = \max(u_2, v_2)$$

sendo: os vetores  $\mathbf{u}$  e  $\mathbf{v}$  são orientados a partir do vetor peso na forma de codificação em complemento  $\mathbf{w}_j = [\mathbf{u}_j \mathbf{v}_j^c]$ . Na Figura 3 representa-se a composição geométrica das categorias.

Figura 3 - Representação geométrica das categorias



Fonte: Lopes (2005)

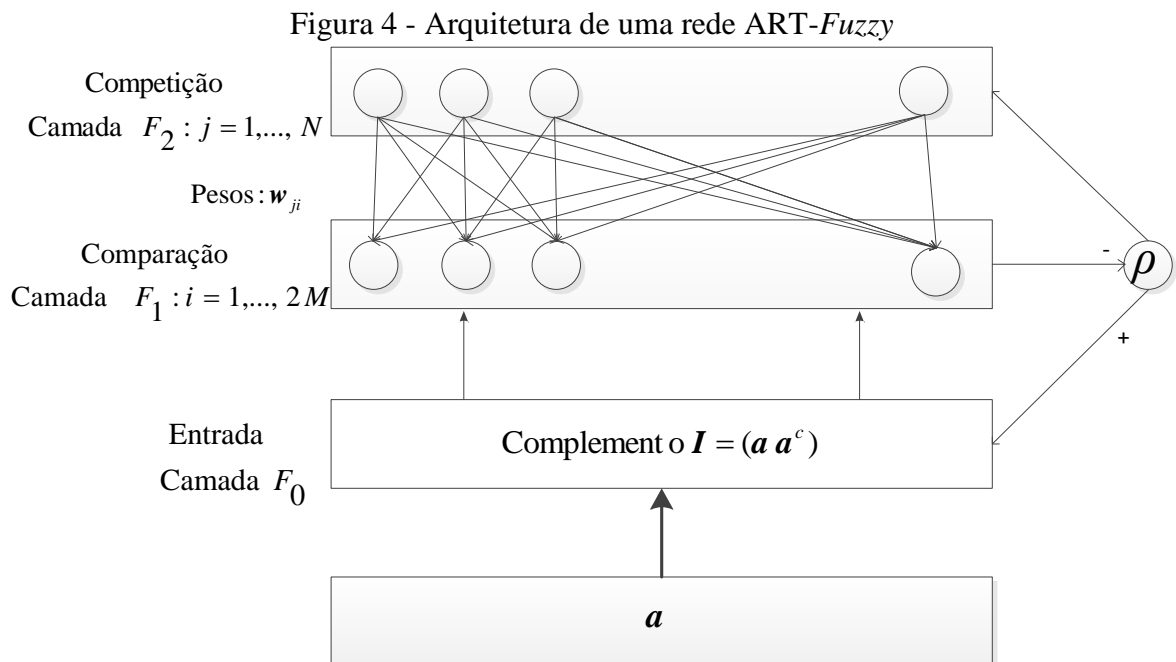
#### 4.2 REDE ART-FUZZY

Uma das diferenças que ocorre na arquitetura das redes ART e ART-Fuzzy é, basicamente a substituição dos operadores de interseção ( $\cap$ ) e união ( $\cup$ ) da rede ART pelos operadores *fuzzy min* ( $\wedge$ ) e *fuzzy max* ( $\vee$ ), respectivamente. Essa troca dos operadores lógicos pelos operadores *fuzzy* possibilita, à RNA ART-Fuzzy, processar dados analógicos compreendidos entre 0 e 1 (CARPENTER; GROSSBERG; ROSEN, 1991b).

A rede ART *fuzzy* necessita de um modo específico de pré-processamento das entradas de modo a evitar a proliferação de categorias, esse pré-processamento se dá com a utilização de padrões com norma constante via codificação em complemento. A mudança dos operadores lógicos, juntamente com a codificação em complemento, possibilita que a amplitude da informação seja preservada e a normalização dos vetores de entrada permite

implementar o algoritmo de classificação não supervisionado com rapidez de aprendizagem (AMORIM, 2006).

Outra diferença que ocorre entre a arquitetura da rede ART e da rede ART *Fuzzy* é nos traços LTM. O fluxo bidirecional de informações entre os campos  $F_1$  e  $F_2$  é realizado por um único conjunto de pesos sinápticos  $w_j$ . Na Figura 4 são ilustrados os campos que a rede ART-*Fuzzy* é composta.




Fonte: Adaptado de Lopes (2005)

Pode-se observar, na Figura 4, que a rede ART-*Fuzzy* é composta por três campos: os campos  $F_0$ ,  $F_1$  e  $F_2$ . Cada campo possui uma função predeterminada que será descrita a seguir.

- **Camada  $F_0$**

A composição do padrão de entrada  $I$ , constituída por operações de normalização e complemento do vetor de entrada ( $a$ ), ocorrem no campo  $F_0$  que representa o vetor de entrada da RNA ART-*Fuzzy*. Na Figura 5 descreve-se o processo realizado na camada  $F_0$ .

Figura 5 - Atividade realizada na camada  $F_0$ 

Fonte: Adaptado de Müller (2018)

**Normalização da entrada:** A normalização do padrão de entrada é realizada para evitar a proliferação de categorias na rede ART. A cada vetor de entrada  $\mathbf{a}$ , apresentada à rede, realiza-se a normalização (CARPENTER *et al.*, 1992; GEORGIOPOULOS *et al.*, 1996):

$$\mathbf{I} = \frac{\mathbf{a}}{\|\mathbf{a}\|} \quad (1)$$

**Complemento do vetor de entrada:** Após a normalização do vetor padrão de entrada realiza-se a codificação do complemento. Essa codificação preserva a amplitude da informação (CARPENTER *et al.*, 1992; GEORGIOPOULOS *et al.*, 1996):

$$a_i^c = 1 - a_i \quad (2)$$

Assim, o vetor de entrada, que no campo  $F_0$  possuía dimensão  $M$  no campo  $F_1$ , terá dimensão  $2M$ , pois:

$$\mathbf{I} = (\mathbf{a} \ \mathbf{a}^c) \quad (3)$$

**Leitura dos parâmetros:** os principais parâmetros da rede são: (1) parâmetro de escolha ( $\alpha > 0$ ), (2) parâmetro de vigilância ( $\rho \in [0,1]$ ) e (3) parâmetro referente à taxa de treinamento  $\beta$ . Estes parâmetros são definidos previamente antes de iniciar o treinamento.

Inicialmente, são atribuídos aos pesos o valor unitário:

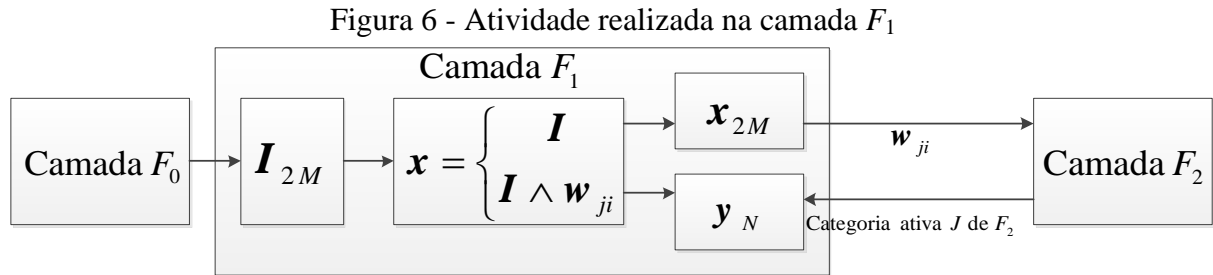
$$W_{j1}(0) = \dots = W_{jM}(0) = 1 \quad (4)$$

Caracterizando (por convenção), assim, que a categoria não foi acionada. Após uma categoria ser selecionada, o vetor peso fica comprometido com a categoria ativa.

- **Camada  $F_1$**

A camada  $F_1$  é um agente de comparação. Ela recebe sinais advindos, tanto da camada  $F_2$  quanto da camada  $F_0$ . O vetor de ativação de  $F_2$  é denotado por  $\mathbf{y} = [y_1 \ y_2 \ \dots \ y_N]$ , sendo

$N$  as categorias criadas em  $F_2$ . Decorrente de uma operação *AND* entre o vetor de atividade  $\mathbf{I}$  e o vetor de pesos  $\mathbf{w}_j$  relativo à categoria ativa  $J$  de  $F_2$ , há a ativação de vetores na camada de comparação  $F_1$  que são denotados por  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_{2M}]$ . Na Figura 6, descreve-se o processo realizado na camada  $F_1$ .

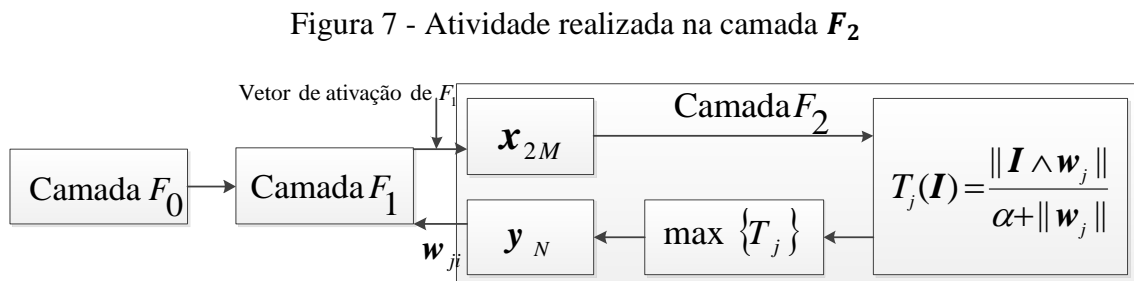


Fonte: Adaptado de Müller (2018)

Entre as camadas  $F_1$  e  $F_2$  existe o peso  $w_{ji}$  que representa a memória da rede. O índice  $i$ , cuja dimensão é  $2M$ , representa os elementos da categoria armazenada. O índice  $j$  representa as categorias criadas na camada  $F_2$ .

- **Camada  $F_2$**

Na camada  $F_2$  ocorre a seleção de categoria ativa  $J$ . O valor da função de escolha  $T_j$  é atribuído a cada unidade de processamento em  $F_2$ , de modo que vence a unidade  $J$  com maior valor. Em caso de empate, é selecionada a categoria  $J$  com  $T_j = \max\{T_j\}$  e menor índice  $J$ . Após o neurônio ser selecionado, na camada  $F_2$ , um protótipo é enviado para  $F_1$  via vetor de ativação  $\mathbf{y} = [y_1 \ y_2 \ \dots \ y_N]$ . Um vetor peso referente ao neurônio é selecionado. Na Figura 7 ilustra-se o processo que ocorre na camada  $F_2$ .



Fonte: Adaptado de Müller (2018)

**Escolha da categoria:** Para cada entrada  $\mathbf{I}$  e um nó  $j$  de  $F_2$ , tem-se a função de escolha  $T_j$ , definida por (CARPENTER et. al, 1992; GEORGIPOULOS et.al., 1996):

$$T_j(I) = \frac{\|I \wedge W_j\|}{\alpha + \|W_j\|} \quad (5)$$

sendo:

$\wedge$  : operador *AND*

$\|\cdot\|$ : norma-1 definida por:

$$|x| = \sum_{i=1}^M |x_i| \quad (6)$$

para qualquer vetor  $M$ -dimensional. A categoria escolhida é indexada por  $J$ , na qual:

$$T_j = \max\{T_j : j = 1, 2, \dots, N\}. \quad (7)$$

Se houver mais de um  $T_j$ , então, escolhe-se o  $j$  correspondente ao menor índice.

Uma vez escolhida a categoria (classe), deve-se proceder a ativação do vetor  $y$  da seguinte forma:

$$\begin{cases} y_j = 1 \\ y_j = 0 \text{ para } j \neq J \end{cases} \quad (8)$$

**Ressonância ou *Reset*:** A ressonância ocorrerá se a função de correspondência da categoria escolhida atender ao critério de vigilância conforme previsto na Equação (9). O parâmetro de vigilância  $\rho$  determina o grau de semelhança exigido no teste de similaridade. Caso o valor de comparação for maior ou igual ao de  $\rho$ , o padrão de entrada é atribuído à categoria ativa, deve-se proceder ao ajuste dos pesos associados à categoria ratificada (formalização da aprendizagem). Caso contrário, recorre-se à atuação do dispositivo *reset*, ou seja, o valor da função de escolha  $T_j$  é fixado em 0 para evitar que a seleção persista na mesma categoria durante o processo de busca. A busca deverá ser realizada até que o padrão sob o índice  $J$  satisfaça a Equação (9) (CARPENTER *et al.*, 1992; GEORGIPOULOS *et al.*, 1996).

$$\frac{\|I \wedge W_J\|}{|I|} \geq \rho \quad (9)$$

**Aprendizagem:** Então, se este critério for satisfeito, a aprendizagem deverá ser providenciada por meio da adaptação dos pesos, de acordo com a Equação (10) (CARPENTER *et al.*, 1992; GEORGIPOULOS *et al.*, 1996):

$$\mathbf{W}_J(n+1) = \beta (\mathbf{I} \wedge \mathbf{W}_J(n)) + (1 - \beta)\mathbf{W}_J(n) \quad (10)$$

Sendo que  $0 < \beta \leq 1$  representa a velocidade da aprendizagem. Caso  $\beta = 1$ , tem-se o caso de aprendizagem rápida, permitindo ao sistema de se adaptar com maior rapidez, conforme a Equação (11).

$$\mathbf{W}_J(n+1) = \beta (\mathbf{I} \wedge \mathbf{W}_J(n)) \quad (11)$$

Se observarmos no âmbito geométrico, pode-se observar que os pesos não crescem com o tempo. Desta forma, o hiper-retângulo somente será expandido. Quando temos um valor de  $\beta < 1$  o hiper-retângulo irá se estender em direção ao ponto na proporção do tamanho de  $\beta$ . Quando  $\beta = 1$  a expansão do hiper-retângulo ocorrerá somente o suficiente para incluir o ponto representado pelo vetor de entrada.

#### 4.3 REDE NEURAL ARTMAP

A rede da família ART, vista até o presente momento, apresenta uma aprendizagem não supervisionada. Contudo, no modelo ARTMAP, baseado nos mesmos princípios e conceitos da rede ART1, possui um aprendizado supervisionado em razão da sua arquitetura.

A rede ARTMAP é composta de um par de módulos ART1, chamada de ARTa e ARTb, que são conectados por meio de um módulo de memória associativa inter-ART,  $F^{ab}$  que estabelece uma correspondência entre eles.

O modelo ARTMAP possui um processo autorregulador muito importante chamado *match tracking*. Esse mecanismo possui a função de realizar a maximização das generalizações e, ao mesmo tempo, minimizar o erro. Ao realizar um prognóstico errado, via uma conexão associativa instruída, o parâmetro de vigilância  $\rho_a$ , do módulo ARTa, é acrescido considerando-se um parâmetro  $\varepsilon$  muito pequeno até atingir a correção do erro no módulo ARTb (CARPENTER; GROSSBERG; REYNOLDS, 1991a).

Uma categoria temporária é escolhida, associada à entrada atual no módulo ARTa, até que o prognóstico seja correto, ou que uma nova categoria seja criada no módulo ARTa e a sua conexão associativa correspondente à categoria do módulo ARTb (LIM; HARRISON, 1997).



A função do módulo ARTa é aprender e classificar os padrões de entrada apresentados na camada  $F_0^a$ , enquanto que a função do módulo ARTb é de desenvolver as categorias referentes aos padrões de saída desejado apresentados na camada  $F_0^b$  por meio do parâmetro de vigilância  $\rho_b$ . Os módulos  $F_2^a$  e  $F^{ab}$  são conectados por um vínculo associativo, cujos pesos são ajustados via treinamento. Já no módulo  $F_2^b$  e  $F^{ab}$ , cada nó de  $F_2^b$  é conectado com seu nó correspondente em  $F^{ab}$  e vice-versa.

Os pesos são adaptados no módulo inter-ART entre uma categoria ativa  $J$  do módulo ARTa e uma categoria ativa  $K$  do ARTb. Quando as categorias são ativas no módulo ARTa e no módulo ARTb é atribuído a elas o valor igual a um e as categorias que não foram ativas são atribuídos valor iguais a zero (LIM; HARRISON, 1997).

A camada  $F^{ab}$  recebe sinal dos dois módulos, tanto do módulo ARTa, quanto do módulo ARTb. A entrada advinda do módulo ARTa refere-se à conexão associativa  $J \rightarrow K$ . A entrada advinda do módulo ARTb corresponde à categoria ativa em  $F_2^b$ . Se houver a concordância entre esses dois sinais dos módulos (ARTa e ARTb), a rede aprenderá modificando seus protótipos das categorias escolhidas em ARTa e em ARTb, segundo um critério de treinamento.

Caso não ocorra uma concordância, entre as categorias dos módulos, ocorrerá o *reset* e o processo denominado *match tracking* ocorrerá de forma que o parâmetro de vigilância  $\rho_a$ , do módulo ARTa, será elevado em uma quantidade mínima ( $\varepsilon$ ) necessária para que não ocorra a combinação para aquela entrada atual do ARTa na camada  $F_1^a$ .

Esse processo faz com que se inicie uma nova busca para escolher uma nova categoria, no módulo ARTa, até que haja o prognóstico correto entre ARTa e a categoria atual de ARTb, ou crie uma nova categoria em  $F_2^a$ , correspondente com o módulo  $F^{ab}$ . Após apresentar o conjunto de treinamento à rede, esta (a RNA) se autoestabilizará e, conseqüentemente, será produzida uma saída esperada para cada entrada apresentada, concluindo, assim, o seu treinamento (CARPENTER; GROSSBERG, 1992).

#### 4.4 REDE NEURAL ARTMAP-FUZZY

A RNA ARTMAP-Fuzzy é o resultado da combinação de duas técnicas: *Adaptive Resonance Theory* (CARPENTER *et al.*, 1992) e a Lógica Fuzzy (ZADEH, 1965). É

constituída por duas RNA ART-*Fuzzy* (ARTa-*Fuzzy* e ARTb-*Fuzzy*) não supervisionadas interligadas por um módulo denominado “inter-ART”.

Adiante, quando se referir à RNA ARTMAP-*Fuzzy*, os módulos ARTa-*Fuzzy* e ARTb-*Fuzzy* serão designados apenas como ARTa e ARTb, respectivamente, como forma de simplicidade de nomenclatura.

Os módulos neurais ARTa e ARTb são responsáveis pelo processamento da entrada (vetor  $\mathbf{a}$ ) e da saída (vetor  $\mathbf{b}$ ), respectivamente. O módulo inter-ART destina-se à realização do “casamento” (mapeamento entrada-saída) entre os dois módulos ARTa e ARTb, proporcionando, à RNA ARTMAP-*Fuzzy*, a extração do conhecimento (treinamento ou aprendizado) de modo supervisionado, ou seja, baseada em estímulos de entrada e de saída.

A lógica *fuzzy* é agregada à arquitetura ARTMAP com vistas a dar maior qualidade às soluções, beneficiando-se do potencial baseado nas operações com conjuntos *fuzzy* que, notadamente, tem sido considerado, na literatura especializada, um incremento de “inteligência” à arquitetura neural. Para tornar viável a aplicação da RNA ARTMAP-*Fuzzy*, a entrada e a saída devem ser pré-processadas considerando-se dois objetivos principais: (1) normalização, ou seja, cada componente dos vetores de entrada e de saída deve estar compreendido entre 0 e 1; (2) a qualidade das soluções a serem obtidas é dependente de uma boa escolha, em função da habilidade do usuário, da codificação dos componentes dos vetores  $\mathbf{a}$  e  $\mathbf{b}$ .

O funcionamento da ARTMAP-*Fuzzy*, para a realização de previsões, consiste nas seguintes fases: (1) fase de treinamento; e (2) fase de análise (previsão). A fase de treinamento é realizada de modo *off-line*, mediante a apresentação somente dos estímulos de entrada (para o treinamento não supervisionado) e de entrada e de saída (treinamento supervisionado), respectivamente. Tais estímulos são elaborados a partir dos exemplos extraídos de uma base de dados e / ou de simulações. O passo a passo do processo de treinamento é descrito a seguir.

**Passo 1:** Os dados de entrada são denominados pelo vetor  $\mathbf{a} = [a_1 \ a_2 \ a_3 \ \dots \ a_M]$  de dimensão  $M$ . Este vetor é normalizado visando evitar a proliferação de categorias (além do mínimo necessário), por conseguinte (CARPENTER *et al.*, 1992; GEORGIPOULOS *et al.*, 1996), tem-se:

$$\bar{\mathbf{a}} = \frac{\mathbf{a}}{\|\mathbf{a}\|_1} \quad (12)$$

sendo:

$\bar{\mathbf{a}}$  : vetor de entrada normalizado;

$$\|\mathbf{a}\|_1 = \sum_{i=1}^M |a_i| \text{ (norma-1)}. \quad (13)$$

Observa-se que para as aplicações das RNA ART-descendentes, combinadas com o emprego da lógica *fuzzy* (que é o caso abordado nesta pesquisa), é exigido que as variáveis e parâmetros, os quais são manipulados internamente (vetores, matrizes), estejam contidos no intervalo  $[0, 1]$ . Portanto, se, originalmente, estes componentes atendem tal restrição, a execução do Passo 1 será dispensada, ou pelo menos, pode ser considerada facultativa, de acordo com os interesses do usuário.

**Passo 2:** A codificação denominada “complemento” é realizada visando preservar a magnitude da informação, ou seja (CARPENTER *et al.*, 1992; GEORGIPOULOS *et al.*, 1996):

$$\bar{a}_i^c = 1 - \bar{a}_i \quad (14)$$

sendo:

$\bar{a}_i^c$  :  $i$ -ésimo componente do vetor complementar de entrada normalizado.

Portanto, a dimensão deste vetor é igual a  $2M$ :

$$\mathbf{I} = (\bar{\mathbf{a}} \ \bar{\mathbf{a}}^c) = (\bar{a}_1 \ \bar{a}_2 \ \dots \ \bar{a}_M \ \bar{a}_1^c \ \bar{a}_2^c \ \dots \ \bar{a}_M^c) \quad (15)$$

$\|\mathbf{I}\|_1$  :  $M$  (todos os vetores com normalização e codificação complementar terão o mesmo comprimento  $M$ ).

**Passo 3:** O vetor de atividade de  $F_2$  é simbolizado por  $\mathbf{y} = [y_1 \ y_2 \ y_3 \ \dots \ y_N]$ , sendo  $N$  o número de categorias criadas em  $F_2$ . Assim, tem-se (CARPENTER *et al.*, 1992; GEORGIPOULOS *et al.*, 1996):

$$y_i = 1, \text{ se o nó } j \text{ de } F_2 \text{ for ativo; } 0, \text{ caso contrário.} \quad (16)$$

**Passo 4:** Os parâmetros utilizados no processamento da RNA ART-*Fuzzy* são (CARPENTER *et al.*, 1992; GEORGIPOULOS *et al.*, 1996):

1. Parâmetro de Escolha :  $\alpha > 0$ ;
2. Taxa de Treinamento :  $\beta \in [0,1]$ ;
3. Parâmetro de Vigilância :  $\rho \in [0,1]$ .

**Passo 5:** Inicialmente, todos os pesos são fixados com valor igual a 1:

$$w_{j1}(0) = w_{j2}(0) = w_{j3}(0) \dots = w_{j2M}(0) = 1 \quad (17)$$

Isto indica que não há nenhuma categoria ativa previamente assumida.

**Passo 6:** Considerando-se o vetor de entrada  $I$  em  $F_1$ , para cada nó  $j$  em  $F_2$ , a função de escolha  $T_j$  é determinada por:

$$T_j = \frac{\|I \wedge \mathbf{w}_j\|_1}{(\alpha + \|\mathbf{w}_j\|_1)} \quad (18)$$

sendo:

$\wedge$  : operador *AND* nebuloso definido por:

$$(I \wedge \mathbf{w})_i = \min(I_i, w_i), i = 1, 2, \dots, N. \quad (19)$$

A categoria é escolhida como sendo correspondente ao nó  $J$  ativo, ou seja:

$$J = \arg\{\max T_j\}, j = 1, 2, \dots, N. \quad (20)$$

Observando-se a Equação (20), se existir mais de uma categoria ativa, a categoria escolhida será aquela que possuir menor índice.

**Passo 7:** A ressonância ocorrerá se o critério de vigilância (Equação (21)) for satisfeito:

$$\|I \wedge \mathbf{w}_J\|_1 / \|I\|_1 \geq \rho \quad (21)$$

Caso o critério, definido pela Equação (21), não for satisfeito, o dispositivo *reset* deverá ser acionado. No ambiente *reset*, o nó  $J$  de  $F_2$  é excluído do processo de busca, ou seja, devendo-se arbitrar  $T_j = 0$ . Então, escolhe-se uma nova categoria, usando-se a Equação (20) no processo de ressonância. Este procedimento deverá ser repetido até que se encontre uma categoria que satisfaça a Equação (21) (CARPENTER *et al.*, 1992; GEORGIPOULOS *et al.*, 1996).

**Passo 8:** Após o vetor de entrada  $I$  ter completado o estado de ressonância, busca-se ajustar os pesos da rede neural *ART-Fuzzy* do seguinte modo (CARPENTER *et al.*, 1992; GEORGIPOULOS *et al.*, 1996):

$$\mathbf{w}_j^{\text{nov}} = \beta (I \wedge \mathbf{w}_j^{\text{velho}}) + (1 - \beta)\mathbf{w}_j^{\text{velho}} \quad (22)$$

sendo:

$J$  : índice da categoria ativa;

$w_j^{\text{nov}} : \text{vetor peso atualizado};$

$w_j^{\text{velho}} : \text{vetor peso referente à atualização anterior.}$

Ressalta-se que, como informado anteriormente, se  $\beta = 1$ , tem-se o treinamento no modo rápido.

Na implementação da RNA ARTMAP-*Fuzzy*, a execução dos módulos ARTa e ARTb segue-se o mesmo procedimento (Passos 1 a 8) associando-se, respectivamente, aos índices  $j$  ( $J$ ) e  $k$  ( $K$ ), *mutatis mutandis*. Os índices  $J$  e  $K$  são os indicadores dos neurônios vencedores em ARTa e ARTb, respectivamente. No módulo ARTb, os parâmetros  $\alpha_b$ ,  $\beta_b$  e  $\rho_b$  são considerados valores fixos arbitrados, via de regra, baseados na experiência. Em relação ao módulo ARTa, também, segue-se com o mesmo algoritmo considerando-se  $\alpha_a$ ,  $\beta_a$  fixos e  $\rho_a$  variável tomando-se inicialmente o seguinte valor (CARPENTER *et al.*, 1992; GEORGIOPOULOS *et al.*, 1996):

$$\rho_{a_{baseline}} = \frac{\|Ia \wedge w_j^a\|_1}{\|Ia\|_1} \quad (23)$$

Incrementa-se o parâmetro  $\rho_a$ , partindo-se do valor inicial da Equação (23), por um valor positivo pequeno continuamente até que o valor de  $\rho_a$  deixar de satisfazer a Equação (21). O último valor de  $\rho_a$  que atender a Equação (21) é o valor correto  $\rho_{a-max}$ , o qual corresponde ao “casamento” entre a categoria pertencente ao padrão de entrada com a categoria associada ao padrão de saída. O parâmetro  $\rho_a$ , compreendido entre  $\rho_{a_{baseline}}$  e  $\rho_{a-max}$ , pode ser percorrido em poucas iterações, conforme destacado por Carpenter and Grossberg (1992). Os pares entrada-saída  $(\mathbf{a}, \mathbf{b})$ , associados aos módulos ARTa e ARTb, são confirmados (as entradas  $\mathbf{a}$  e  $\mathbf{b}$  referem-se às categorias  $J$  e  $K$  ativas, respectivamente), mediante o teste do *match tracking*:

$$(x^{ab})_i = \frac{|y_i \wedge w_j^{ab}|_1}{|y_i|_1} \quad (24)$$

$(x^{ab})_i \geq \rho_{ab} \rightarrow$  o par de treinamento  $(\mathbf{a}, \mathbf{b})$  deve ser confirmado nas matrizes de pesos com índices  $J$  e  $K$ .

$(x^{ab})_i < \rho_{ab} \rightarrow$  deve-se buscar outro índice  $J$  (com relação aos vetores de entrada  $I_a$ ), mantendo-se o índice  $K$ , até que o critério de ressonância seja satisfeito.

sendo:

$\rho_{ab}$  : parâmetro de vigilância do módulo inter-ART.

Os pesos  $\mathbf{w}^a$  e  $\mathbf{w}^b$  devem ser adaptados usando-se a Equação (22). Em relação aos pesos  $\mathbf{w}^{ab}$ , deve-se proceder da seguinte forma:

$$\begin{aligned} \mathbf{w}_{JK}^{ab \text{ novo}} &= 1 \\ \mathbf{w}_{Jk}^{ab \text{ novo}} &= 0, \text{ para } k \neq K. \end{aligned} \quad (25)$$

#### 4.5 COMENTÁRIOS

Neste capítulo, foi realizado um estudo sobre a teoria da ressonância adaptativa, mostrando as principais redes da família ART, tanto as com o treinamento supervisionado tanto com o treinamento não supervisionado. Também, foi detalhada a sua arquitetura mostrando a função de cada equação na estrutura da rede, e a função de cada módulo  $F_0, F_1,$  e  $F_2$ . Em especial, foi mostrado o passo a passo da rede ARTMAP-*Fuzzy*, no qual a mesma será uma das ferramentas utilizadas para a realização da previsão de carga elétrica proposta nesta tese.

## 5 METODOLOGIA

Neste Capítulo são apresentadas as metodologias propostas no intuito de realizar a previsão de cargas multinodais. As metodologias são todas baseadas na rede neural artificial ARTMAP-*Fuzzy*, e como ferramenta de avaliação de desempenho emprega-se o MAPE. Foi desenvolvido um total de quatro metodologias, a Tabela 1 descreve as principais características de cada uma das metodologias.

Tabela 1- Metodologias e suas características.

Metodologia	Característica	
Metodologia 1	Sistema Previsor com o corretor <i>Pro Rata</i>	Três módulos: (1) Global; (2) Local e (3) corretor <i>Pro Rata</i> , que realiza a correção a cada iteração.
	Sistema Previsor com o corretor <i>Pro Rata</i> ao final	Três módulos: (1) Global; (2) Local e (3) corretor <i>Pro Rata</i> , que realiza a correção ao final do processo de previsão.
Metodologia 2	Sistema Previsor Regional	Três módulos: (1) Global; (2) Regional e (3) Local.
Metodologia 3	Sistema Previsor Local	Dois módulos: (1) Global e (2) Local. O processamento dos módulos ocorre de forma paralela.
Metodologia 4	ARTMAP- <i>Fuzzy</i> com treinamento reverso	Dois módulos: (1) Global e (2) Local. As informações do ART a global são inseridas como entrada de todos os módulos locais

Fonte: Elaborado pela própria autora.

Visando corrigir as curvas referentes à previsão multinodal, emprega-se um procedimento definido nesta pesquisa como *Pro Rata*. Trata-se de uma forma simples para ajustar as curvas auferidas na saída do módulo associado à previsão multinodal. Este procedimento corresponde à primeira ideia usada nesta pesquisa, o qual tem proporcionado melhorias dos resultados (precisão). Ressalta-se que este dispositivo poderá ser aperfeiçoado, levando-se conta um grande número de simulações, cujo modelo poderá ser desenvolvido combinando-se a lógica *fuzzy* (ZADEH, 1965), bem como com outra rede neural. Trata-se de algo que será objeto de sugestão para trabalho futuro.

### 5.1 SISTEMA PREVISOR DE CARGAS LOCAIS COM CORRETOR *PRO RATA*

Nesta primeira metodologia o sistema previsor é baseado em três módulos distintos: (1) módulo global; (2) módulo multinodal local e (3) módulo corretor. Dependendo da posição do módulo corretor têm-se dois métodos distintos.

### 5.1.1 Método 1

Inicialmente, realiza-se a PCG, via rede neural ARTMAP-*Fuzzy*, baseada no uso do dispositivo “movimento de janela” (PARK *et al.*, 1991). Trata-se de um recurso (modelo) mais usualmente empregado na literatura especializada. Neste sentido, define-se o vetor de entrada  $\mathbf{a}$ :

$$\mathbf{a} = [d \ h \ CG(h - 2) \ CG(h - 1) \ CG(h)] \quad (26)$$

sendo:

$d$  : codificação referente ao dia da semana (vetor de três bits: de domingo – [000] a sábado – [110]);

$h$  : codificação de hora em intervalos de 30 minutos (vetor de seis bits: de 00:00 – [000000] às 23:30h – [101111]);

$CG(h - 2)$  : carga global referente ao instante  $h - 2$ ;

$CG(h - 1)$  : carga global referente ao instante  $h - 1$ ;

$CG(h)$  : carga global referente ao instante  $h$ .

Já o vetor de saída  $\mathbf{b}$  corresponde ao valor da carga global correspondente ao instante  $h + 1$ , *i.e.*, 30 minutos à frente.

$$\mathbf{b} = [CG(h + 1)] \quad (27)$$

Na fase da previsão da carga global, o valor de  $CG(h + 1)$  apurado na saída de RNA corresponde à previsão 30 minutos à frente, ou outro tipo de discretização de interesse do usuário.

Vale ressaltar que as variáveis de entrada, as quais são constituídas, na presente formulação, podem ser alteradas por valores de cargas em outros instantes de tempo (presente e passadas) e por outras variáveis exógenas como, por exemplo, temperatura, humidade, velocidade do vento, entre outras. Isto se deve ao fato da arquitetura ARTMAP-*Fuzzy* não possuir restrições em relação à dimensão do vetor de entrada e, muito menos, em relação à dimensão do conjunto de padrões para a fase de treinamento.

Após o treinamento utilizando os vetores  $\mathbf{a}$  e  $\mathbf{b}$  definidos anteriormente realiza-se uma avaliação para verificar se os pesos foram adaptados corretamente. Se os resultados não forem satisfatórios, os parâmetros da rede neural são alterados e um novo treinamento é realizado até



resultar em uma previsão desejada. A métrica utilizada para verificar a precisão da resposta obtida com a rede é o *Mean Absolute Percent Error* (MAPE) (PARK *et al.*, 1991).

$$MAPE = \frac{1}{NA} \sum_{h=1}^{NA} \left| \frac{y_{atual}(h) - y_{previsto}(h)}{y_{atual}(h)} \right| * 100\% \quad (28)$$

sendo:

$NA$  : número de amostragens de ½ em ½ hora da série temporal;

$y_{atual}(h)$  : valor de referência (comparação) relativo ao instante  $h$ ;

$y_{previsto}(h)$  : valor previsto atinente ao instante  $h$ .

No caso da previsão multinodal, a carga global prevista ( $CG(h + 1)$ ) será utilizada como entrada dos módulos locais juntamente com os fatores de participação de cada subestação. O fator de participação é definido conforme a equação (29) (ALTRAN, 2010; NOSE-FILHO *et al.*, 2011):

$$FPCG_p(h) = \frac{CL_p(h)}{CG(h)} \quad (29)$$

sendo:

$CL_p(h)$  : valor da carga na subestação  $p$  em relação ao instante  $h$ ;

$CG(h)$  : carga total do sistema em relação ao instante  $h$ .

Neste sentido, define-se o vetor de entrada dos módulos locais, conforme definido na Equação (30).

$$\mathbf{a}_p = [CG(h + 1) FPCG_p(h) FPCG_p(h - 1) FPCG_p(h - 2)] \quad (30)$$

O vetor de saída  $\mathbf{b}_p$  corresponde ao fator de participação da carga global da subestação  $p$  para o instante  $h + 1$ , i.e., 30 minutos à frente.

$$\mathbf{b}_p = [FPCG_p(h + 1)] \quad (31)$$

para  $p = 1, 2, \dots, n$ .

sendo:

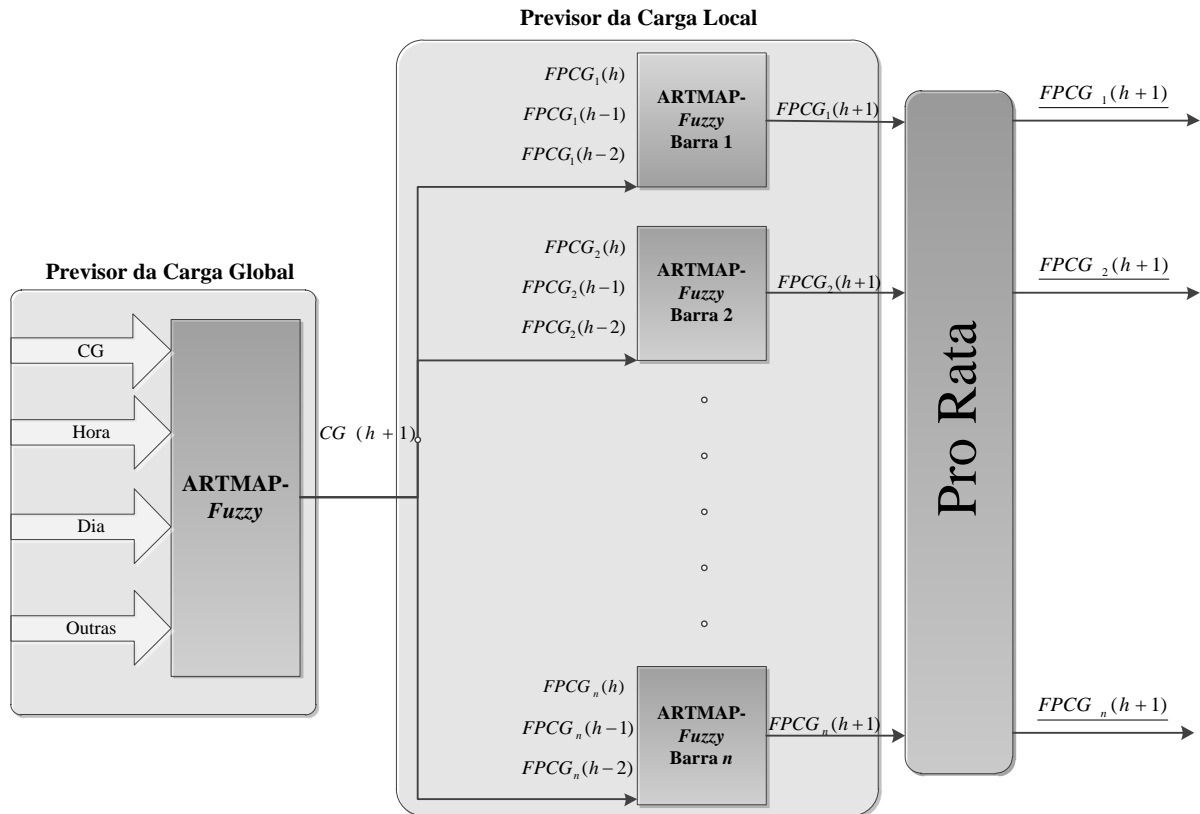
$n$  : número de nós de interesse da rede elétrica;

$p$  : índice de identificação do nó de interesse;

$FPCG_p$  : Fator de Participação da Carga Global associado à  $p$ -ésima barra.

Na Figura 8, ilustra-se o sistema predictor proposto para realizar a previsão de carga multinodal. Destaca-se que os valores apurados neste sistema são a carga global (total) e as cargas nos diversos barramentos de interesse de modo normalizado, sendo convertidos aos valores reais (em Watts) ao final do processo.

Figura 8 - Sistema de previsão de carga



Fonte: Elaborado pela própria autora

O treinamento é efetuado até completar a base de dados proposto escolhida. A saída obtida do PCL é o  $FPCG_p(h+1)$  referente a cada nó de interesse. Após a previsão da hora  $h+1$ , um corretor é empregado para ajustar a saída da rede neural, sendo o mesmo denominado *Pro Rata*. O algoritmo do corretor é de simples implementação e não requer esforço computacional adicional. A seguir será descrito este algoritmo passo a passo (ABREU *et al.*, 2018).

**Passo 1:** Considerando a previsão correspondente à hora  $(h+1)$ , obtém o valor predito de:

$FPCG_p(h+1)$ , para  $p \in \mathcal{I}$ , sendo:  $\mathcal{I}$  nós de interesse;

**Passo 2:**  $soma = \sum_{p \in \mathfrak{J}} FPCG_p(h + 1)$ ;

**Passo 3:**  $erro = 1 - soma$ ;

**Passo 4:**  $|erro| \leq tol$  ?, Se sim, Pare. Se não, vá para Passo 5;

**Passo 5:**  $FPCG_p(h + 1) = (1 + erro) FPCG_p(h + 1)$ , para  $p \in \mathfrak{J}$ . Retorne para o Passo 2;

sendo:

$tol$  : tolerância preestabelecida.

O valor do FPCG, ajustado pelo corretor, será inserido no PCL como entrada para a próxima previsão, *i.e.*, hora  $h + 2$ . Tal processo é repetido até que se complete as 24 horas. Na Tabela 2 exemplifica-se a forma como as entradas são inseridas no PCL.

Tabela 2 - Entradas do sistema predictor local

Hora	Entrada do PCL	Saída do Corretor <i>Pro Rata</i>
$h$	$[CG(h + 1) \underline{FPCG_p(h - 2)} \underline{FPCG_p(h - 1)} \underline{FPCG_p(h)}]$	$[\underline{FPCG_p(h + 1)}]$
$h + 1$	$[CG(h + 2) \underline{FPCG_p(h - 1)} \underline{FPCG_p(h)} \underline{FPCG_p(h + 1)}]$	$[\underline{FPCG_p(h + 2)}]$
$h + 2$	$[CG(h + 3) \underline{FPCG_p(h)} \underline{FPCG_p(h + 1)} \underline{FPCG_p(h + 2)}]$	$[\underline{FPCG_p(h + 3)}]$
...	...	...
$h + n$	$[CG(h + n + 1) \underline{FPCG_p(h + n - 2)} \underline{FPCG_p(h + n - 1)} \underline{FPCG_p(h + n)}]$	$[\underline{FPCG_p(h + n + 1)}]$

Fonte: Elaborado pela própria autora

Após as 24 horas serem devidamente previstas é necessário transformar o fator de participação em valor de carga em MW. Por fim, têm-se os valores previstos para carga global e carga local, para um período de 24 horas, de acordo com as equações (32) e (33), respectivamente:

$$\overline{CG}(h) = (\overline{b}_1(h)) \times L_{base} \quad (32)$$

$$\overline{L}_p(h) = \underline{FPCG_p(h)} \times \overline{CG}(h) \quad (33)$$

para  $h = 1, 2, \dots, 24$ ;

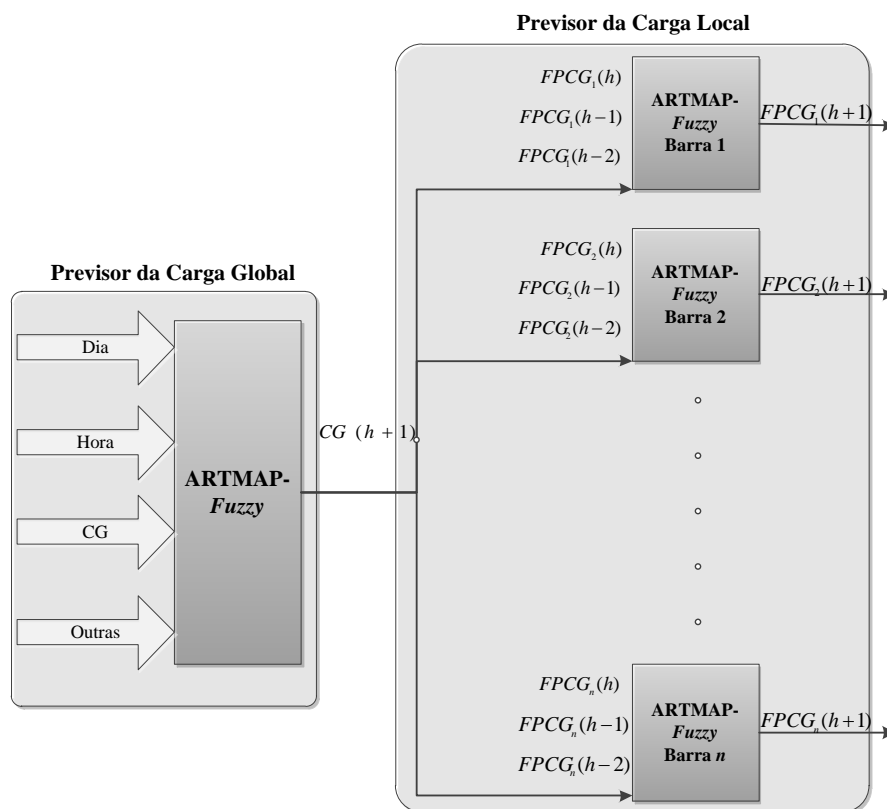
sendo:

- $\overline{CG}(h)$  : carga total prevista para o instante  $h$ ;
- $\overline{b}_1(h)$  : valor da saída da RNA (previsor global) atinente ao instante  $h$ ;
- $L_{base}$  : valor da carga total tomada como base no processo de normalização;
- $\overline{L}_p(h)$  : valor da saída da  $p$ -ésima RNA (previsor local) correspondente ao instante  $h$ ;
- $\underline{FPCG}_p(h)$ : valor previsto de  $FPCG$  associado ao  $p$ -ésimo módulo local correspondente à hora  $h$ .

### 5.1.2 Método 2

Como mencionado anteriormente, a primeira metodologia possui duas estruturas distintas. Depende da posição em que se encontra o corretor *Pro Rata*, a método 1, descrita anteriormente, possui uma correção iterativa com o sistema previsor local. A proposta, relativa à método 2, difere por estar inserida somente ao final de todo o processo de previsão, após as 24 horas estarem previstas. A correção via corretor *Pro Rata*, é realizada de  $\frac{1}{2}$  em  $\frac{1}{2}$  hora em cada subestação resultando assim em uma correção pontual. A Figura 9 ilustra como é realizada a correção proposta no segundo método.

Figura 9 - Fluxograma da segunda proposta de correção



Fonte: Elaborado pela própria autora

Uma vez concluída a previsão dos  $FPCG_n$  para todas as barras, deve-se corrigir tais fatores via o uso do algoritmo Pro Rata.

### 5.1.3 Ajuste e Seleção dos Nós de Interesse

Considerando-se a definição apresentada na equação (29), conclui-se que:


$$\sum_{p=1}^n \{FPCG_p(h)\} = 1 \quad (34)$$

Assim, se  $n$  for muito grande, podem ocorrer valores muito pequenos de  $FPCG_p(h)$  que, conseqüentemente, podem prejudicar o desempenho do treinamento da RNA. Neste caso, sugere-se usar um *fator de multiplicação* ( $mf_p$ ) para cada  $FPCG_p(h)$  (execução de mudança de escala), tal que o resultado desta multiplicação represente os valores mais convenientes para o treinamento da RNA.

No ato da previsão, deve-se fazer-se o devido ajuste, ou seja, realizar a divisão de  $FPCG_p(h)$  por  $mf_p$ . Para fins ilustrativos, pode-se considerar um  $FPCG$  pequeno se a sua média for inferior a 0,05 (5%), por exemplo. Contudo, ressalta-se que todos os vetores  $I_b$  (entradas da RNA ARTb) possuem o mesmo tamanho  $M$ . Então, valores pequenos dos seus componentes são compensados com o uso do conceito “complementação” conforme a Equação (14). Por conseguinte, não produzindo danos importantes neste contexto, como observado em experimentos realizados.

Esta estratégia, baseada no emprego do conceito do  $FPCG$ , representa uma grande economia de cálculo e de rapidez na execução, principalmente, da fase de treinamento, visto que o  $FPCG$  possui um espectro pequeno de variação em torno de um valor médio para todos os nós de interesses considerados no experimento. Isto faz com que a RNA se comporte com maior estabilidade e maior rapidez na obtenção de uma solução. Ilustra-se na Figura 10 o comportamento típico de um  $FPCG$ , correspondente a todas as subestações do sistema num período de 24 horas.

Figura 10 - Comportamento típico do FPCG



Fonte: Elaborado pela própria autora

Deste modo, podem-se seleccionar os pontos (nós) de interesse para fins da previsão nodal, definindo-se o seguinte conjunto de nós:

$$\mathcal{I} = \{ \mathcal{I}_I, \mathcal{I}_A \} \quad (35)$$

sendo:

$\mathcal{I}_I$ : conjunto dos nós de interesse;

$\mathcal{I}_A$ : nó agregado.

Os nós de  $\mathcal{I}_I$  são tratados individualmente como sendo associados às cargas multinodais de interesse. A carga relativa a  $\mathcal{I}_A$  corresponde ao somatório de todas as cargas que não fazem parte (excluentes) de  $\mathcal{I}_I$ . Por conseguinte, se  $\dim\{\mathcal{I}_I\} = m$ , então,  $\dim\{\mathcal{I}\} = m + 1$ .

O tempo de execução do treinamento, o qual representa a maior parcela, considerando-se o paralelismo do sistema predictor, pode ser estimado de acordo com a Expressão (36):

$$T_{total} \cong T_{PCG} + T_{PCL} < 2 T_{PCG} \quad (36)$$

sendo:

$T_{total}$  : tempo total de execução do treinamento do sistema predictor (global e multinodal);

$T_{PCG}$  : tempo total de execução do treinamento da RNA global;

$T_{PCL}$  : tempo total de execução do treinamento da RNA local correspondente ao tempo médio de execução dos diversos módulos locais.

Observando-se a Expressão (36), o tempo total destinado à execução da RNA ARTMAP-*Fuzzy* ( $T_{total}$ ) é inferior a ( $2 T_{PCG}$ ), em razão do tempo médio de execução dos módulos locais ser inferior em comparação com a execução da previsão global, isto porque a dimensão do vetor  $\mathbf{a}_p$  (Equação (30)) é bastante inferior à dimensão do vetor  $\mathbf{a}$  (Equação (26)). Ressalta-se, ainda, que a RNA ARTMAP-*Fuzzy*, como constatado na literatura especializada e argumentado anteriormente, é centenas de vezes mais rápida, quando comparada à RNA *feedforward* multicamadas com o treinamento realizado via o algoritmo *backpropagation* (WERBOS, 1974), a qual tem sido a mais usada na resolução da previsão de carga.

## 5.2 SISTEMA PREVISOR REGIONAL

A segunda proposta de metodologia baseia-se na separação das subestações por regiões considerando sua localização geográfica. Inicialmente, é realizada a previsão da carga global e, em seguida, são realizadas as desagregações em níveis menos complexos de barras, *i.e.*, regional e local. As regiões geralmente são agrupadas de acordo com suas características climáticas, econômicas, culturais, entre outras. Se as informações acerca da localização geográfica das subestações estiverem disponíveis no banco de dados, isto poderá trazer vantagens ao procedimento de previsão.

O comportamento do consumo regional é realizado por um Sistema Previsor Regional (SPR) inserido entre as previsões global e local. Como consequência, as previsões regionais obtidas são inseridas como dados de entrada do sistema previsor local. Essa abordagem faz com que os dados de entrada sejam mais refinados e contribuem para reduzir o erro.

A entrada do sistema previsor global é o mesmo descrito na Equação (26). A saída fornecida pelo SPG é  $CG(h + 1)$  será inserida juntamente com a carga regional definida pela equação (37) como entrada no sistema previsor regional.

$$CR_k(h) = \frac{\sum_{n=1}^k FPCCG_n(h)}{CG(h)} \quad (37)$$

A entrada e saída do sistema previsor regional são definidas nas Equações (38) e (39), respectivamente.

$$\mathbf{a}_{SPR} = [CG(h + 1) CR_k(h - 2) CR_k(h - 1) CR_k(h)] \quad (38)$$

$$\mathbf{b}_{SPR} = [CR_k(h + 1)] \quad (39)$$

sendo:

$CG(h + 1)$  : carga global prevista referente à hora  $h + 1$ ;

$CR_k(h - 2)$  : carga regional na hora  $h - 2$ ;

$CR_k(h - 1)$  : carga regional na hora  $h - 1$ ;

$CR_k(h)$  : carga regional na hora  $h$ , sendo  $k$  a região de interesse.

A saída do SPR conforme definida na Equação (39) é uma das entradas do sistema previsor local juntamente com os fatores de participação da carga global com três amostras de antecedência do instante  $h$ . Portanto, a entrada deste sistema previsor local é definida pela Expressão (40). Na saída, tem-se o FPCG previsto, conforme definido na Equação (41).

$$\mathbf{a}_{SPL} = [CR_k(h + 1) FPCG_p(h - 2) FPCG_p(h - 1) FPCG_p(h)] \quad (40)$$

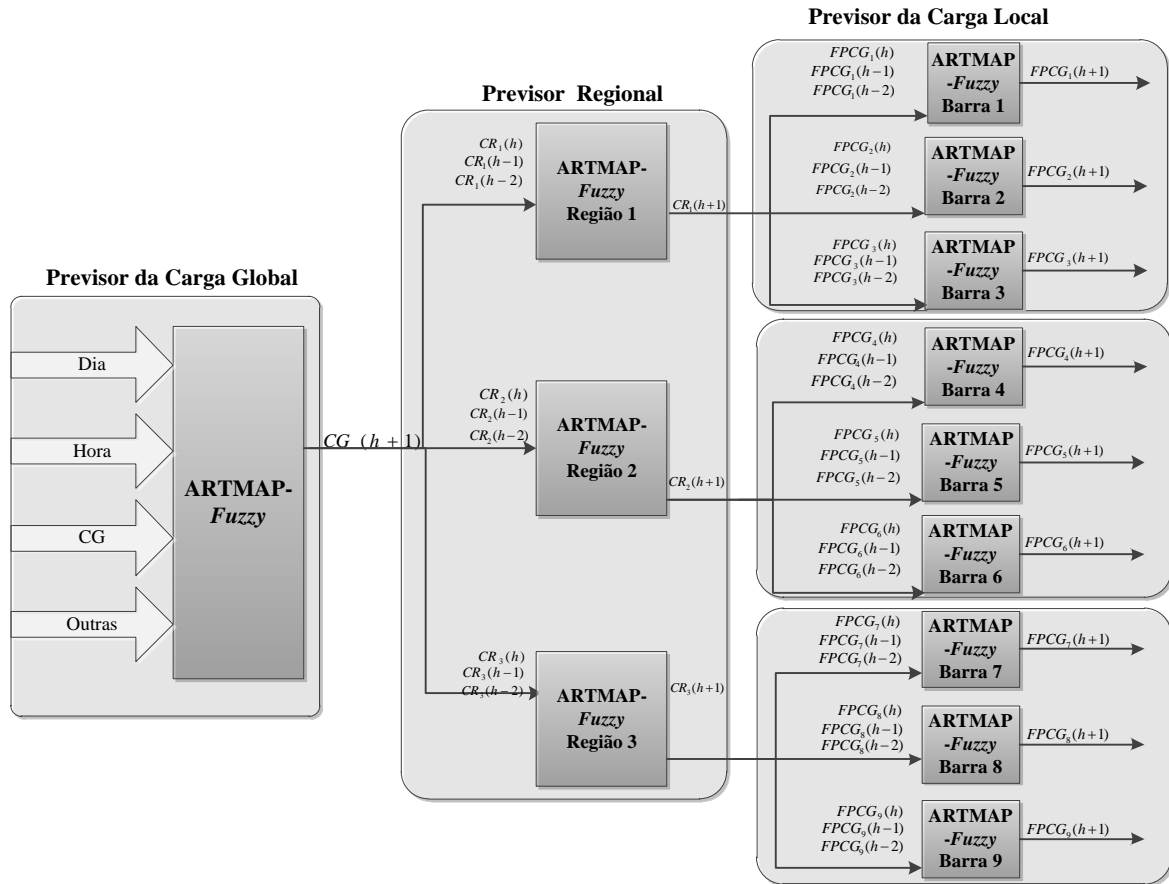
$$\mathbf{b}_{SPL} = [FPCG_p(h + 1)] \quad (41)$$

O valor previsto, ao final do processo, corresponde ao fator de participação de cada subestação barra. No final deste processo, há a necessidade de conversão deste valor para MW (processo descrito nas Equações (32) e (33)).

A Figura 11 ilustra o processo desenvolvido para realizar a previsão local através do sistema previsor regional.



Figura 11 - Sistema predictor regional



Fonte: Elaborado pela própria autora.

### 5.3 SISTEMA PREVISOR LOCAL

Uma terceira proposta de análise refere-se à realização da previsão multinodal utilizando o sistema predictor global de forma paralela com os sistemas predictores locais. Com essa nova conjuntura, a entrada dos módulos locais é realizada conforme definida na Expressão (42).

$$\mathbf{a}_{SPL} = [FPCG_p(h-2) FPCG_p(h-1) FPCG_p(h)] \quad (42)$$

sendo:

$\mathbf{a}_{SPL}$  : entrada do sistema predictor local;

$FPCG_p(h)$  : fator de participação da carga global atinente à hora  $h$ ;

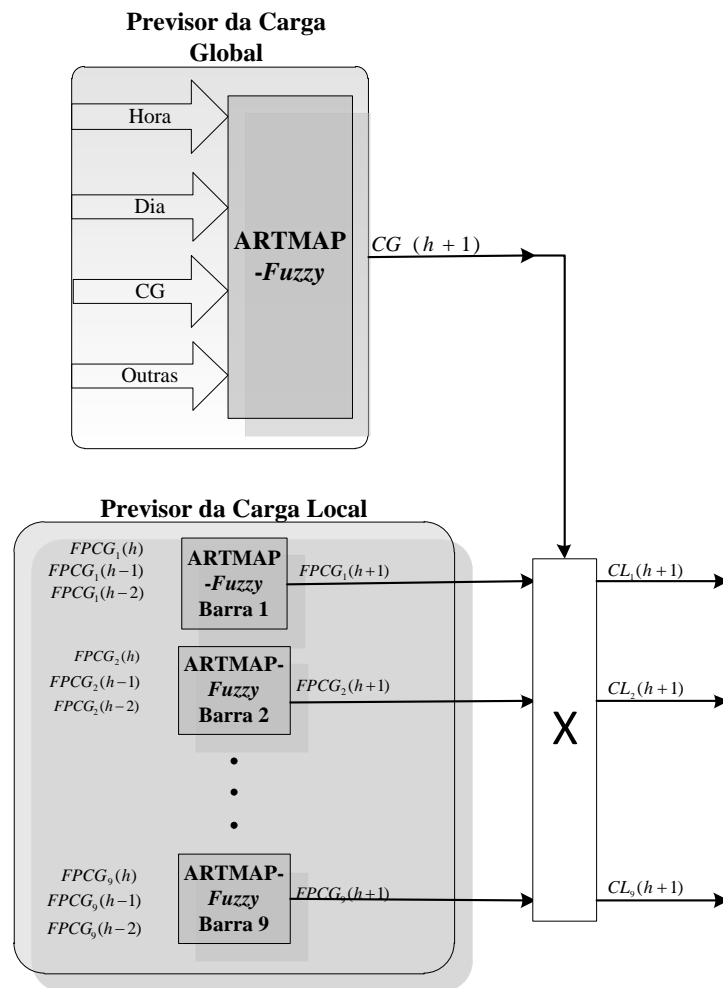
$p$  : número de nós de interesse.

A entrada do sistema predictor global é composta por informações como dia, hora e carga global, conforme mostra a equação (26), com o objetivo de prever a carga global de um período à frente (por exemplo, 1 hora ou  $\frac{1}{2}$  hora) conforme a equação (27).

Por fim, o valor de carga local final previsto nas 24 horas à frente é definido de acordo com as Equações (32) e (33).

A Figura 12 ilustra a metodologia desenvolvida para realiza a previsão local.

Figura 12 - Sistema predictor local



#### 5.4 ARTMAP-FUZZY COM TREINAMENTO REVERSO

De acordo com a exposição da primeira metodologia com seus métodos, foi apresentada uma metodologia para a resolução da previsão de carga multinodal baseada nos seguintes recursos: (1) o uso de uma rede neural da família ART (ARTMAP-Fuzzy), (2) Sistema Predictor e (3) o ajuste da previsão fundamentado num procedimento nominado de *Pro Rata*. Nesta seção, será sugerida uma metodologia alternativa para previsão de carga

multinodal com o propósito inicial de melhorar a qualidade (reduzir o erro previsível) das soluções. Obviamente, constitui-se num ambiente que necessita ser bastante explorado, seja no sentido de aperfeiçoar o modelo matemático, bem como na realização de um grande número de experimentos.

No algoritmo ARTMAP clássico, o módulo inter-ART tenta combinar uma categoria escolhida na  $ART_a$  para uma categoria pré-existente na  $ART_b$ . Se não for possível fazer essa correspondência, a reinicialização ocorrerá no  $ART_a$  e o processo será repetido até que um par de (entrada / saída) “casado” seja encontrado. Então, é possível concluir que o coordenador do módulo inter-ART é  $ART_b$  por causa do dispositivo *reset* ocorrer apenas no lado da entrada da rede. A partir desta perspectiva, um novo método para treinar a RNA é desenvolvido, onde a  $ART_a$  agora é o coordenador do módulo inter-ART. Esta forma de treinamento é denominada, nesta pesquisa, como o treinamento reverso (TR).

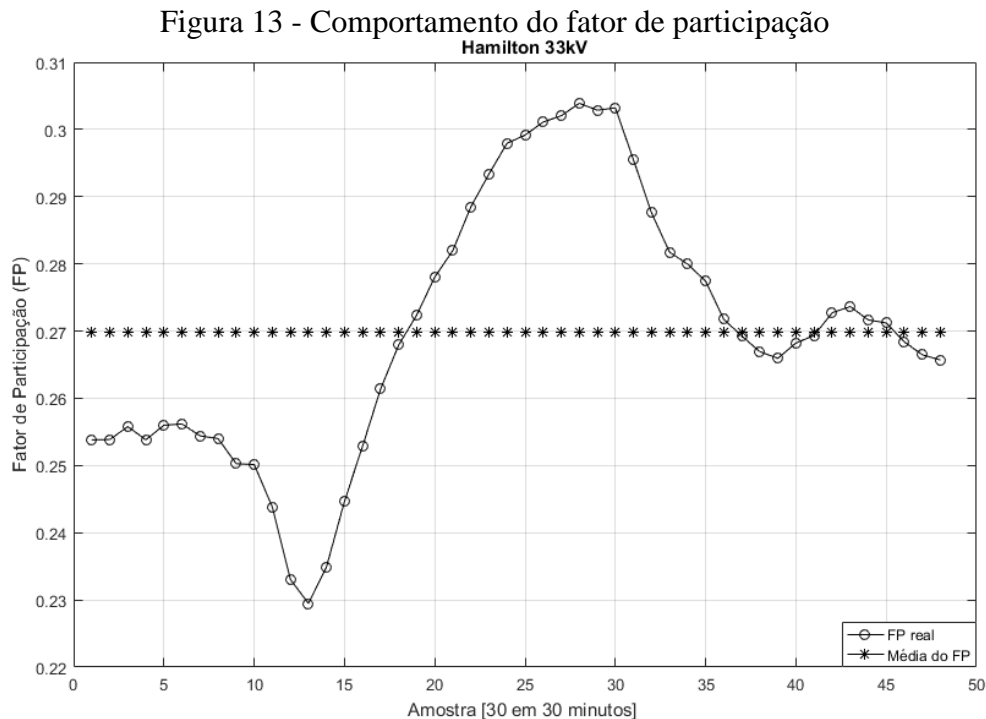
O treino reverso consiste em mover o módulo  $ART_a$  para a posição de  $ART_b$  e vice-versa. Embora o inter-ART mantenha a posição no algoritmo, foi necessário redesenhar todas as suas expressões para satisfazer as mudanças mencionadas. Outro ponto a considerar é que o treinamento reverso só pode ser implementado se a matriz de pesos  $W^a$  é carregada de uma rede ARTMAP-*Fuzzy* treinada existente (por exemplo, procedente da RNA relativa à previsão global com treinamento concluído) e as entradas usadas são as mesmas informações da ARTMAP-*Fuzzy* anterior (previsão global). Por exemplo, se no vetor de entrada da RNA ARTMAP-*Fuzzy* são usados a temperatura, pressão e velocidade do vento, o vetor de entrada do sistema neural com treinamento reverso deve usar essas mesmas informações para funcionar adequadamente.

Este conceito se concentra em resolver o problema relacionado à criação descontrolada de categorias pela RNA ARTMAP-*Fuzzy*, o que poderia reduzir a eficiência computacional e produzir saídas erradas (resultados incorretos). Quando se usa uma matriz  $W^a$  pronta o sistema tem apenas a preocupação de criar categorias na  $ART_b$  (na matriz  $W^b$ ) e combiná-los com as categorias em  $W^a$ , diminuindo o erro e aumentando a estabilidade da rede neural.

### 5.4.1 Previsão da Carga Local com Treinamento Reverso

A previsão de carga local é idealizada utilizando o conhecimento extraído do treinamento global, onde o conceito de fator de participação da carga global (FPCG) é aplicado. Esta quantidade apresenta uma menor variação em seu comportamento durante o período de 24 horas, ou seja, sua evolução temporal é semelhante ao consumo de energia da subestação  $CL_p$ , trazendo vantagem ao processamento da RNA ARTMAP-*Fuzzy* em fase de treinamento.

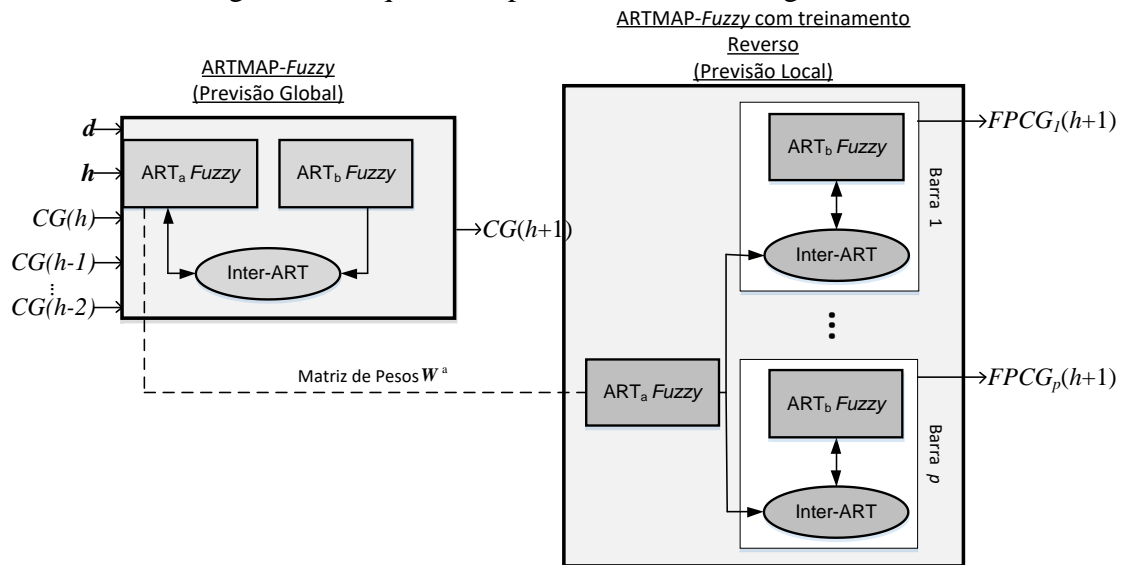
Na Figura 13, ilustra-se o comportamento do fator participação, definido na Equação (29), considerando a carga média de uma subestação em um período de 24 horas. Pode-se observar a alternância do consumo quando comparada com a carga média. Isso se deve à dependência do fator hora, dia, condições climáticas, entre outros. Assim, para se obter uma previsão multinodal precisa, não se recomenda adotar distribuições imprecisas sob o risco de produzir previsões incorretas e, conseqüentemente, comprometer a análise da rede elétrica.



Então, o valor do FPCG de cada subestação (30 minutos à frente) é usado para compor o vetor de saída (Equação (41)) para treinar a RNA ARTMAP-*Fuzzy* com treinamento reverso.

O vetor de entrada da ARTMAP-Fuzzy com treinamento reverso é o mesmo que o apresentado na Equação (26). Além disso, o conhecimento armazenado na matriz de pesos  $W^a$  ARTMAP-Fuzzy treinada é agora carregado para este sistema neural. Finalmente, depois de treinado, o MAPE é aplicado. A metodologia de previsão de carga multinodal é executada em dois distintos passos: (1) extração de características da carga global e (2) previsão da carga local. A Figura 14 ilustra a formulação alternativa para a previsão de carga multinodal.

Figura 14- Esquema de previsão da metodologia 4



Fonte: Elaborado pela própria autora.

O passo-a-passo do algoritmo da rede neural ARTMAP-Fuzzy, com treinamento reverso, é apresentado a seguir.

**Passo 1.** Definir os parâmetros  $(\alpha, \beta, \rho_a, \rho_b, \rho_{ab}, e \varepsilon)$ ;

**Passo 2.** Carregar o parâmetro  $\rho_a$  e a matriz de pesos  $W^a$  da RNA ARTMAP-Fuzzy previamente treinada;

**Passo 3.** Matrizes de pesos são inicializadas ( $W_{(N,2Mb)}^b = 1$  e  $W_{(N,N)}^{ba} = 1$ );

**Passo 4.** Realizar a operação de complemento dos vetores  $a^c$  e  $b^c$  (como estabelecido na Equação (14), respectivamente) visando compor os vetores de entrada e de saída da RNA:

$$I^a = \begin{bmatrix} a & a^c \end{bmatrix} \text{ e}$$

$$I^b = \begin{bmatrix} \mathbf{b} & \mathbf{b}^c \end{bmatrix}.$$

**Passo 5.** Lista de padrões para treinamento está terminado?

Se sim, a fase de treinamento esta concluída.

Se não,  $\rho_a = \underline{\rho}_a$  vá para o passo 6;

**Passo 6.** Determinar a função de escolha do módulo  $ART_{a-Fuzzy}$ ,  $T_j^a = \frac{\|I \wedge w_j\|_1}{\alpha + \|w_j\|_1}$ , para

$$j = 1, 2, \dots, N;$$

**Passo 7.** Escolher a categoria da RNA  $ART_{a-Fuzzy}$ , com  $jw = \arg \left\{ \max \left( T_j^a \right) \right\}$ , para

$$j = 1, 2, \dots, N;$$

**Passo 8.** Critério de vigilância de  $ART_{a-Fuzzy}$ :  $\frac{\|I^a \wedge w_{jw}^a\|}{\|I^a\|} \geq \rho_a$  é satisfeito?

Se sim, vá para o passo 9;

Se não, proceder à atuação do dispositivo *reset* atribuindo a  $T_{jw}^a = 0$  e retorne ao passo 7;

**Passo 9.** Calcular  $Y^a = [Y_1 \ Y_2 \ \dots \ Y_N]$ , com  $Y_j^a = 1$  para  $j = jw$  e  $Y_j^a = 0$  para  $j \neq jw$ ;

**Passo 10.** Determinar a função de escolha de  $ART_{b-Fuzzy}$ :  $T_k^b = \frac{\|I^b \wedge w_k^b\|_1}{\alpha + \|w_k^b\|_1}$ , para

$$k = 1, 2, \dots, N;$$

**Passo 11.** Escolher uma categoria de  $ART_{b-Fuzzy}$ , com  $kw = \arg \left\{ \max \left( T_k^b \right) \right\}$ , para

$$k = 1, 2, \dots, N;$$

**Passo 12.** Critério de vigilância de  $ART_{b-Fuzzy}$ :  $\frac{\|I^b \wedge w_{jw}^b\|}{\|I^b\|} \geq \rho_b$  é satisfeito?

Se sim, vá para o passo 13;

Se não, proceder a atuação do *reset*, atribuindo  $T_{kw}^b = 0$  e retorne ao passo 11;

**Passo 13.** Critério de vigilância de inter-ART:  $\frac{\|Y^a \wedge w_{kw}^{ba}\|}{\|Y^a\|} \geq \rho_{ba}$  é satisfeito?

Se sim, vá para o passo 14;

Se não, proceder a atuação do *reset*, atribuindo  $T_{kw}^b = 0$  e retorne ao passo 11;

**Passo 14.** Adaptar os pesos dos módulos

$$ART_{b-Fuzzy}: W_{kw}^{b(novo)} = \beta \left( I^b \wedge W_{kw}^{b(velho)} \right) + (1 - \beta) W_{kw}^{b(velho)};$$

Inter-ART:  $W_{kw}^{ba} = [W_{kw,1}^{ba} W_{kw,2}^{ba} \dots W_{kw,N}^{ba}]$ , com  $W_{kw,j}^{ba} = 1$  para  $j = jw$  e  $W_{kw,j}^{ba} = 0$  para  $j \neq jw$ ;

**Passo 15.** Retornar ao passo 5.

#### 5.4.2 Processamento de Tempo

Considerando que o treinamento e que as previsões podem ser executados com o processamento paralelo, a previsão completa (global+multinodal) deve ser obtida em um tempo bastante competitivo. Desse ponto de vista, os métodos baseados em redes neurais *feedforward* treinados, com retropropagação devem ser evitados, em razão de: (1) na execução do algoritmo retropropagação necessita de um grande número de épocas para produzir bons resultados e; (2) frequentemente, apresenta problemas de convergência. Por outro lado, a rede neural ARTMAP-*Fuzzy* é imune a problemas de convergência, ou seja, encontra sempre uma solução, e precisa apenas de uma época para gerar os resultados, ou seja, depende fortemente do ajuste dos parâmetros, o que a torna uma das melhores técnicas para o campo de previsão de estudo.

Existem duas variáveis relacionadas ao tempo de processamento das redes neurais associadas ao treinamento global e ao local:  $t_{processamento}^{CG}$  e  $t_{processamento}^{CL}$ . O tempo total necessário para treinar todas as redes é:

$$t_{processamento}^{total} = t_{processamento}^{CG} + t_{processamento}^{CL} \quad (43)$$

sendo:

$t_{processamento}^{total}$  : tempo total de processamento;

$t_{processamento}^{CG}$  : tempo de processamento global;

$t_{processamento}^{CL}$  : tempo de processamento subestação  $p_{th}$ .

Depois de simulações realizadas exaustivamente, foi observado o seguinte fato:

$$t_{processamento}^{CL} \cong 3 * t_{processamento}^{CG} \quad (44)$$

Então, o tempo total de processamento para treinar as redes neurais pode ser estimado com a Equação (46).

$$t_{processamento}^{total} \cong 4 * t_{processamento}^{CG} \quad (45)$$

Neste caso de estudo, é altamente recomendado o uso de processamento paralelo no sistema multinodal para obter o resultado final em um curto período de tempo. No entanto, se o processamento é em série, a previsão multinodal considerando-se as  $p$ -barras (subestações) serão concluídas em:

$$t_{processamento}^{total} \cong (1 + p) * t_{processamento}^{CG} \quad (46)$$

Deve-se destacar que o  $t_{processamento}^{CG}$  é muito competitivo em relação às redes neurais artificiais tradicionais disponíveis na literatura e mencionadas anteriormente.

## 5.5 COMENTÁRIOS

Neste capítulo foram apresentadas de forma detalhada, as quatro metodologias propostas. A primeira metodologia que elucida a abordagem realizada tais como: a utilização da RNA ARTMAP-*Fuzzy*, o sistema previsor, a proposta de correção *Pro Rata* e a concatenação das abordagens foram discutidas por meio de dois métodos.

O primeiro método possui o sistema previsor que é composto por um previsor global, um previsor local e um corretor *Pro Rata* que é um corretor que, por meio de poucas instruções possibilita realizar o ajuste das curvas de carga hora a hora retornando esse valor para o sistema previsor local, e este por sua vez prevê a próxima hora que passa pelo corretor novamente que corrige e insere essa correção como a nova entrada do sistema previsor e, assim por diante, até completar as 24 horas de previsão.

O segundo método possui a mesma composição de rede, de sistema previsor e corretor *Pro Rata* a diferença que a correção é realizada somente ao final da previsão das 24 horas de previsão. Ao final da previsão os valores previstos pela rede são inseridos no corretor e a correção é realizada hora a hora tendo como saída o valor de carga local corrigido sem a necessidade de voltar ao módulo previsor.

Já a segunda e a terceira metodologias não utilizam o corretor *Pro Rata*, porém utilizam os demais procedimentos, no caso da segunda metodologia há uma divisão em três sistemas previsores, primeiramente o previsor global, depois um previsor regional e por fim um previsor local, a proposta de um previsor regional é para preservar as características comuns que uma região possui. A terceira metodologia contempla uma alteração da entrada



da RNA, utilizando-se assim somente os valores do FPCG com uma janela de três horas antecedentes para prever uma hora à frente.

Foi apresentada, também, neste capítulo uma metodologia alternativa intitulada *ARTMAP-Fuzzy* com treinamento reverso para previsão de carga multinodal que contempla a qualidade das soluções e a rapidez das respostas, uma proposta inovadora que apresenta expectativas positivas nos primeiros testes realizados.

## 6 RESULTADOS E DISCUSSÕES

Visando testar a eficiência da metodologia proposta, para resolver o problema da previsão multinodal, foram realizadas várias simulações. Todas as simulações e os testes foram produzidos usando-se um PC Core i7-2600 3.40 GHz e 8.00 GB de RAM com o *software* Matlab.

A base de dados das séries históricas do consumo de energia elétrica foi fornecida por uma concessionária da Nova Zelândia (CDS, 2010). Trata-se da região onde estão localizadas as subestações, a qual é conhecida como Waikato. Essa região é composta por várias subestações, porém, nosso banco de dados é composto por nove subestações: Cambridge, Hamilton 11 kV, Hamilton 33 kV, Hinuera, Kinleith, Kopu, Te Awamutu, Waihou e Waikino. Na Figura 15 mostra-se o mapa das subestações em que a região de Waikato é composta.

Figura 15 - Região de Waikato



Fonte: Transpower Transmission Network (2018)

A utilização dessa base de dados é em razão da disponibilidade na internet (TRANSPower TRANSMISSION NETWORK, 2010). Contudo, outras bases de dados, se disponíveis, podem ser, perfeitamente, usadas. Embora o conjunto de dados compreenda um período de 25 meses, apenas um mês (8 de dezembro de 2008 a 7 de janeiro de 2009) de consumo foi usado para treinar as redes neurais, o que corresponde a 1.488 pontos de carga (31 dias x 48 medições por dia). O objetivo é um dia inteiro de previsão (8 de janeiro de 2009), ou seja, 24 horas com previsão em intervalos de 30 minutos (48 pontos).

Várias informações são disponibilizadas no banco de dados da aludida concessionária. Porém, foram utilizadas as variáveis exógenas tais como: dia da semana, hora e os dados de carga local e global. Para a entrada do sistema previsor global foi utilizada a expressão (47), resultando como saída, a carga global prevista pela RNA ARTMAP-*Fuzzy* que é expressa como na equação (48).

$$\mathbf{a} = [\text{Variáveis Exógenas } CG(h-2) \ CG(h-1) \ CG(h)] \quad (47)$$

$$\mathbf{b} = CG(h+1) \quad (48)$$

Como forma de avaliar o desempenho da metodologia, utiliza-se o MAPE descrito na equação (28). Esse parâmetro também serve como indicador para fins da análise comparativa entre os métodos previsionais.

## 6.1 RESULTADO DO SISTEMA PREVISOR GLOBAL

O primeiro resultado, que foi analisado, refere-se à previsão da carga total que é realizada no sistema previsor global. A carga, prevista neste passo, será utilizada em todas as metodologias. Os dados de entrada do sistema previsor global são compostos pelas variáveis exógenas: dia e hora e por uma amostra de três cargas globais antecedentes ao instante de interesse, conforme é descrito na equação (47). A RNA ARTMAP-*Fuzzy* possui a capacidade de processar padrões de entrada analógicos e/ou binários. Desta forma, os dias e as horas são “binarizados”. O valor da carga global é normalizado para que os padrões de entrada fiquem compreendidos entre 0 e 1. A normalização adotada é definida na equação (49):

$$CG(h) = \frac{CG(h)}{\text{Max } CG * 1,20} \quad (49)$$

sendo:

$CG(h)$  : carga global referente ao instante  $h$ ;

$Max CG$  : carga global máxima presente no banco de dados.

A escolha dos parâmetros a serem utilizados na RNA é imprescindível para que haja uma previsão eficiente. Na Tabela 3 mostram-se os parâmetros utilizados durante o período de treinamento da RNA no sistema predictor global.

Tabela 3 - Parâmetros utilizados no sistema predictor global

Parâmetros	$\alpha$	$\beta$	$\rho_a$	$\rho_b$	$\rho_{ab}$	$\varepsilon$
-	0,11	1	0,5	0,9920	1	0,000001

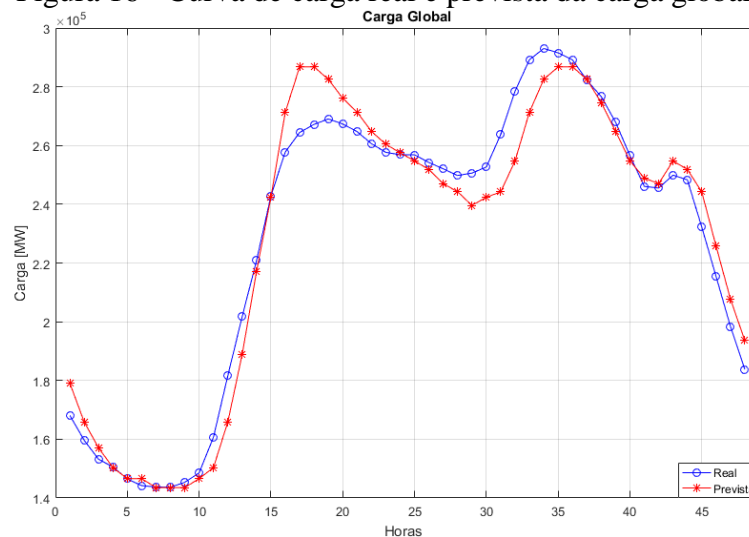
Fonte: Elaborado pela própria autora.

Esses parâmetros foram obtidos através de testes utilizando um algoritmo simples, cujo passo era incrementar os parâmetros de vigilância ( $\rho_a$ ,  $\rho_b$ ) e o parâmetro de escolha ( $\alpha$ ) dentro do intervalo ao qual eles pertencem e realizar a melhor combinação possível entre eles para obter um MAPE satisfatório.

### 6.1.1 Análise Gráfica das Curvas de Carga Previstas e Reais do SPG

Uma forma de analisar a metodologia adotada é por meio da plotagem da curva prevista e a curva real da carga para analisar o comportamento da previsão. Na Figura 16 ilustram-se a curva de carga real (cor azul) e a curva de carga prevista (cor vermelha).

Figura 16 - Curva de carga real e prevista da carga global



Fonte: Resultado da pesquisa

### 6.1.2 Análise do MAPE do Sistema Previsor Global

O critério adotado para aferir a eficácia da metodologia é via a inferência do erro percentual absoluto médio (MAPE), como informado anteriormente. Na Tabela 4 apresenta-se o valor de MAPE obtido com o sistema previsor.

Tabela 4 - MAPE da previsão global

	MAPE
Global	3,04

Fonte: Resultado da pesquisa

## 6.2 RESULTADOS DA PRIMEIRA METODOLOGIA

A primeira metodologia foi dividida em dois métodos. Estes métodos se diferem conforme a posição em que se encontra o corretor *Pro Rata*. Sendo assim, no intuito de verificar qual método apresenta uma previsão significativa utilizam-se as mesmas subestações em ambas as situações. Foram selecionadas algumas subestações para serem avaliadas, as subestações que apresentaram um baixo consumo de energia (potência) foram agregadas e tratadas como uma única subestação. Neste caso, foram consideradas as subestações Waikino, Hinuera e Kinleith conforme se pode observar na Figura 10. Ressaltando que essa é uma sugestão de agregação podendo ser alterada conforme a necessidade do usuário.

### 6.2.1 Parâmetros Utilizados na RNA ARTMAP-Fuzzy

A rede neural ARTMAP-Fuzzy possui parâmetros que são imprescindíveis para o funcionamento da RNA. A escolha do parâmetro de modo correto proporciona um bom desempenho da rede realizando, assim, previsões satisfatórias. Os parâmetros utilizados para o treinamento da rede estão relacionados na Tabela 5.

Tabela 5 - Parâmetros utilizados na rede para cada subestação

Parâmetros	Kopu	Waihou	Hamilton 11 kV	Hamilton 33 kV	Cambridge	Te_Awamutu	Agregadas
$\alpha$	0,7	0,7	0,7	0,7	0,7	0,7	0,7
$\beta$	1	1	1	1	1	1	1
$\rho_a$	0,9	0,9	0,9	0,9	0,9	0,9	0,9
$\rho_b$	0,999	0,999	0,999	0,999	0,999	0,999	0,999
$\rho_{ab}$	1	1	1	1	1	1	1
$\epsilon$	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005

Nota: Agregadas: Waikino, Hinuera e Kinleith

Fonte: Elaborada pela própria autora.

## 6.2.2 Análise do MAPE dos métodos 1 e 2

Na Tabela 6 são mostrados os valores de MAPE obtido com a metodologia proposta.

Tabela 6 - MAPE obtido com os métodos 1 e 2

Item	Kopu	Waihou	Hamilton 11 kV	Hamilton 33 kV	Cambridge	Te Awamutu	Agregadas
Sem Correção	11,01	4,0	5,50	4,20	4,70	4,99	3,44
Método 1	5,85	4,22	5,49	4,73	4,95	5,00	3,84
Método 2	4,99	3,42	5,63	4,76	4,75	3,31	3,85

Nota: Agregadas: Waikino, Hinuera e Kinleith


Fonte: Resultado da pesquisa.


## 6.2.3 Análise Gráfica das Curvas de Cargas Previstas e Reais dos métodos 1 e 2

Uma forma de analisarmos a eficiência da metodologia proposta é por meio da curva de carga correspondente ao dia previsto. Dessa forma, a seguir serão apresentadas as curvas de carga real na cor azul e a curva de carga prevista no método 1 na cor vermelha. A curva de carga real e a curva prevista foram realizadas considerando-se intervalos de tempo de 30 minutos, totalizando 48 dados que corresponde ao período de um dia (24 horas).

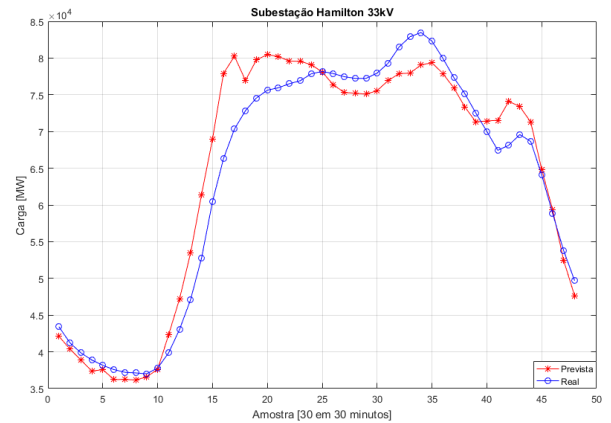
O conjunto de ilustrações apresentadas na Figura 17 corresponde à curva de carga real e à curva prevista das subestações: (a) Kopu, (b) Waihou, (c) Hamilton 11kV, (d) Hamilton 33kV, (e) Cambridge, (f) Te Awamutu, (g) Agregadas (Waikino, Hinuera e Kinleith) e (h) Global (somatório das cargas locais previstas).

Figura 17 - Conjunto de curvas de cargas prevista no método 1

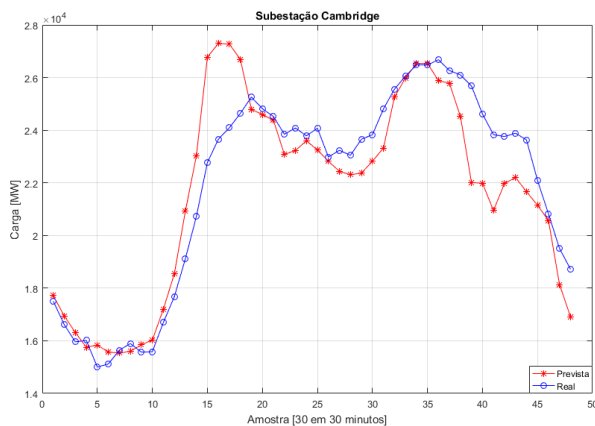





(c)



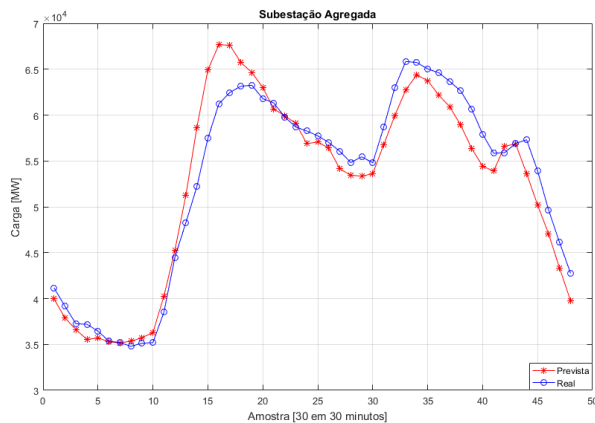
(d)




(e)



(f)



(g)



(h)

Nota: Agregadas: Waikino, Hinuera e Kinleith

Fonte: Resultado da pesquisa.

Observa-se que as curvas previstas acompanham as curvas de carga real, porém há alguns pontos em que a curva prevista fica abaixo da curva real. De um modo geral, apresentam um resultado significativo, em razão do erro percentual aceitável deverá ficar abaixo de 5% para o setor de energia. Uma subestação que houve uma melhora muito significativa foi a Kopu considerando-se os métodos 1 e 2. O método 1 apresentou uma melhora de 46.87%, enquanto que no método 2 houve uma melhora de 54,67% no valor da

carga prevista. Ressaltando que o corretor proposto é apenas um embrião e poderá ser aperfeiçoado com melhorias em sua estrutura inserindo, por exemplo, conteúdos no contexto da lógica *fuzzy*. Ou seja, pode-se, perfeitamente, desenvolver um procedimento semelhante ao corretor *Pro rata*, porém à luz da teoria da lógica *fuzzy*. Este algoritmo não foi desenvolvido nesta pesquisa, ficando como sugestão para trabalhos futuros.

### 6.3 RESULTADOS DA SEGUNDA METODOLOGIA

Na segunda metodologia é proposta uma inserção um sistema previsor regional entre o sistema previsor global e o local. Para analisarmos a eficiência desse procedimento, foi realizada a análise de desempenho, igualmente, baseada na métrica MAPE, considerando-se as curvas referentes à carga real *versus* à carga prevista. Primeiramente, as subestações: Kopu, Waikino e Waihou são agrupadas e designadas como Região 1. As subestações Cambridge, Hamilton 11kV e Hamilton 33kV são agrupadas e atribuídas como Região 2. Finalmente, as subestações Te Awamutu, Hinuera e Kinleith são agrupadas na Região 3. Após a previsão regional, realiza a previsão local considerando-se todas as nove subestações.

#### 6.3.1 Análise do MAPE da Segunda Metodologia

A Tabela 7 mostra os MAPE obtidos primeiramente no sistema previsor regional e logo após tem-se o MAPE das subestações obtidas através do sistema previsor local.

Tabela 7 - MAPE regional e local obtido com segunda metodologia.

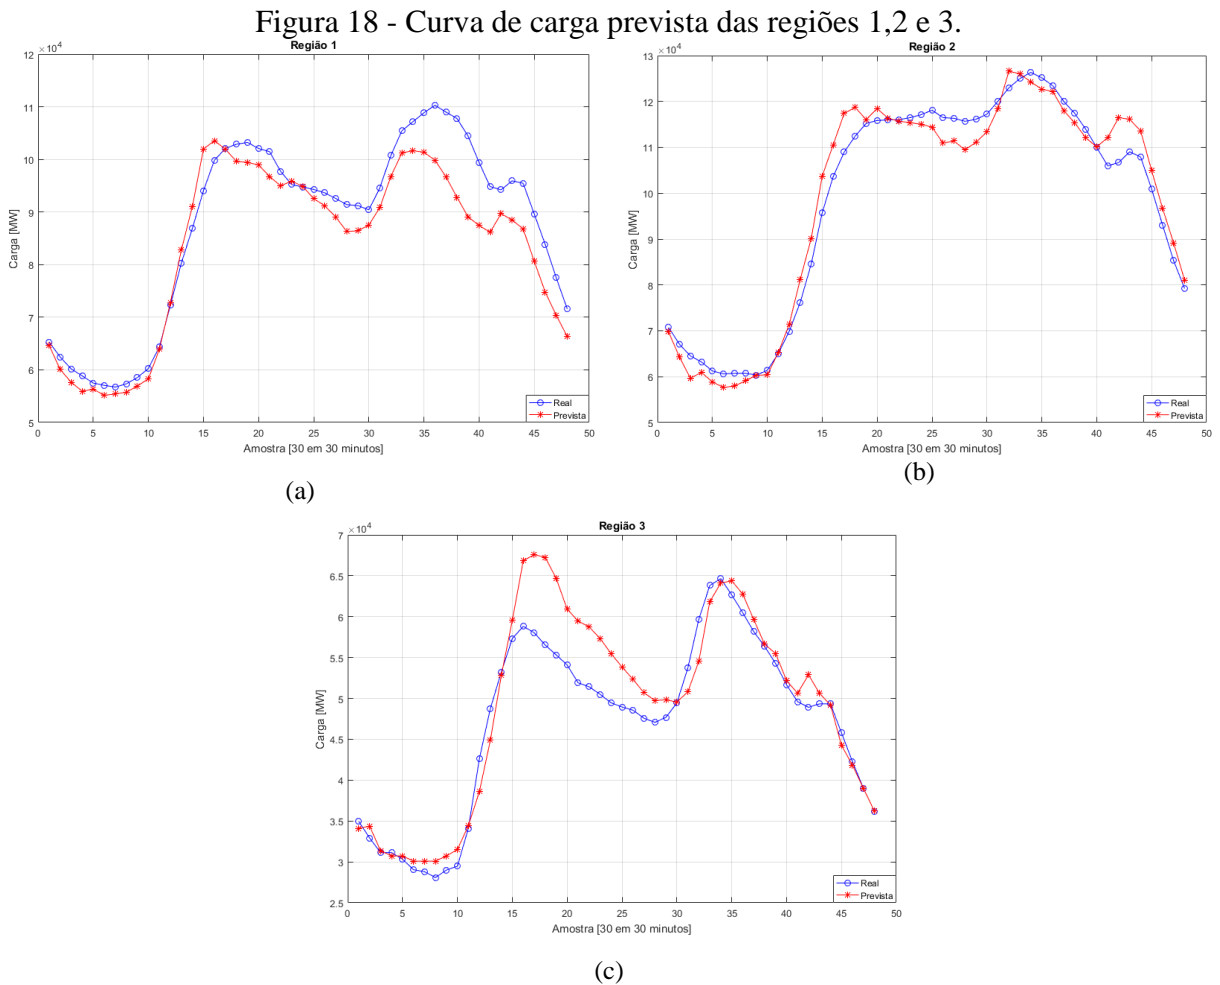
Regiões	MAPE Regional	Subestações	MAPE (%)	Tempo de Processamento (s)
Região 1	5,12	Kopu	8,52	22,90
		Waikino	5,79	22,41
		Waihou	3,62	21,41
Região 2	3,46	Cambridge	4,18	20,98
		Hamilton 11kV	4,40	20,62
		Hamilton 33kV	2,77	21,76
Região 3	5,78	Te Awamutu	5,57	21,97
		Hinuera	5,01	21,23
		Kinleith	6,07	20,99
Global (Somatório das Locais)			2,31	0,24

Fonte: Resultado da pesquisa.



### 6.3.2 Análise Gráfica das Curvas de Cargas Previstas e Reais da Segunda Metodologia




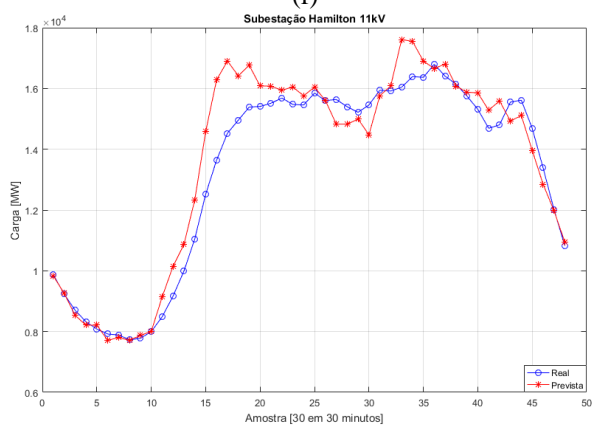
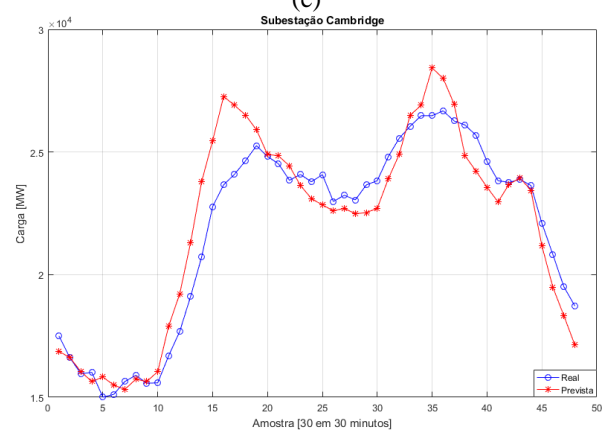

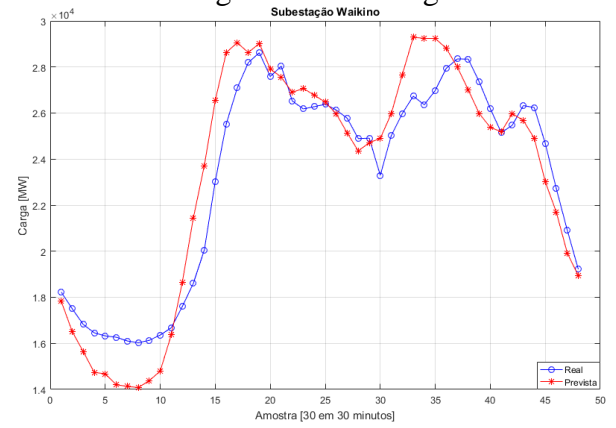
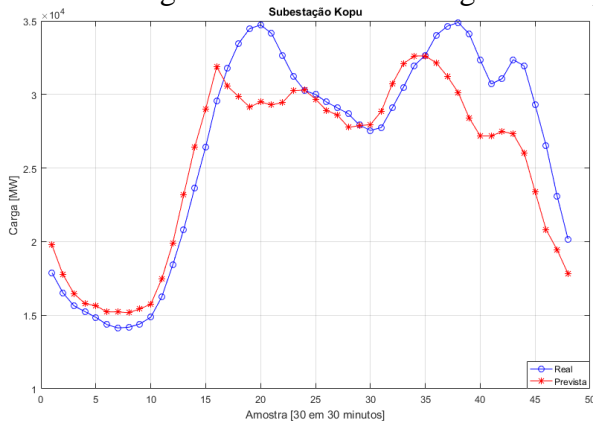
A análise gráfica, também, foi realizada com o propósito de verificar o comportamento da curva de carga prevista em relação à curva da carga real. Desta forma, tem-se a curva da carga real (cor azul) e a curva de carga prevista (cor vermelha) geradas via aplicação da segunda metodologia. O conjunto de figuras apresentadas na Figura 18 contém a curva de carga das regiões predefinidas, sendo a figura (a) Região 1, (b) Região 2 e (c) Região 3.



Fonte: Resultado da pesquisa.


O conjunto de figuras apresentado Figura 19 corresponde às curvas das cargas locais (d) Subestação Kopu, (e) Subestação Waikino, (f) Subestação Waihou, (g) Subestação Cambridge, (h) Subestação Hamilton 11kV, (i) Subestação Hamilton 33kV, (j) Subestação Te Awamutu, (k) Subestação Hinuera, (l) Subestação Kinleith e (m) Global (Somatório das cargas locais).

Figura 19 - Curvas de cargas locais provenientes da segunda metodologia.



(j)

(k)



Fonte: Resultado da pesquisa.

Ao analisarmos os resultados obtidos com a segunda metodologia, percebe-se que algumas subestações tiveram bons resultados ficando com MAPE abaixo de 5%. Porém, três das subestações saíram um pouco dessa faixa de 5% e duas das subestações extrapolaram esse valor. O tempo de processamento é muito relevante no processo de previsão. Neste caso, observa-se, por meio dos resultados obtidos, que o tempo máximo da previsão local foi 23 segundos.

Deve-se ressaltar que este tempo de processamento é muitíssimo menor, se comparado com algoritmo *backpropagation* (WERBOS, 1974), como usado em grande parte das publicações na literatura. Destaca-se, ainda, em muitos casos, quando se emprega *RNA-backpropagation*, não se consegue auferir a convergência, *viz.*, não se consegue obter a plena segurança sobre os resultados produzidos.

## 6.4 RESULTADOS DA TERCEIRA METODOLOGIA

A terceira metodologia que possui o sistema predictor global e o sistema predictor local, conforme descrito anteriormente, porém, o que é alterado é a entrada do SPL, no qual a entrada SPL é somente o FPCG com um janelamento, considerando-se de três cargas passadas. Este procedimento proposto foi descrito no Capítulo 5, no subitem 5.3. A análise de eficiência desse procedimento foi realizado, também, baseado na métrica MAPE.

### 6.4.1 Análise do MAPE Referente à Terceira Metodologia

Na Tabela 8 mostram-se os MAPE das subestações obtidos com a aplicação da terceira metodologia proposta nesta pesquisa.

Tabela 8 - MAPE das subestações obtido com a terceira metodologia.

Subestação	MAPE (%)	Tempo de Processamento (s)
Kopu	3,68	25,45
Waikino	4,71	21,87
Waihou	4,29	23,76
Cambridge	3,95	21,40
Hamilton 11kV	3,35	22,89
Hamilton 33kV	3,96	21,58
Te Awamutu	4,74	22,82
Hinuera	6,18	21,27
Kinleith	4,34	17,49
Global (Somatório das cargas Locais)	2,32	0,24


Fonte: Resultado da pesquisa


#### 6.4.2 Análise Gráfica das Curvas de Cargas Previstas e Reais da Terceira Metodologia

A análise gráfica, também, foi realizada visando verificar o comportamento da curva de carga prevista em relação à curva da carga real. Assim, tem-se a curva carga real (traçado azul) e a curva de carga prevista (traçado vermelho).


O conjunto de Figura 20 corresponde às curvas das cargas locais (a) Subestação Kopu, (b) Subestação Waikino, (c) Subestação Waihou, (d) Subestação Cambridge, (e) Subestação Hamilton 11kV, (f) Subestação Hamilton 33kV, (g) Subestação Te Awamutu, (h) Subestação Hinuera e (i) Subestação Kinleith e (j) Somatório de todas as previsões locais (previsão global).

Figura 20 - Curvas de cargas locais provenientes da terceira metodologia.







(c)




(d)




(e)




(f)



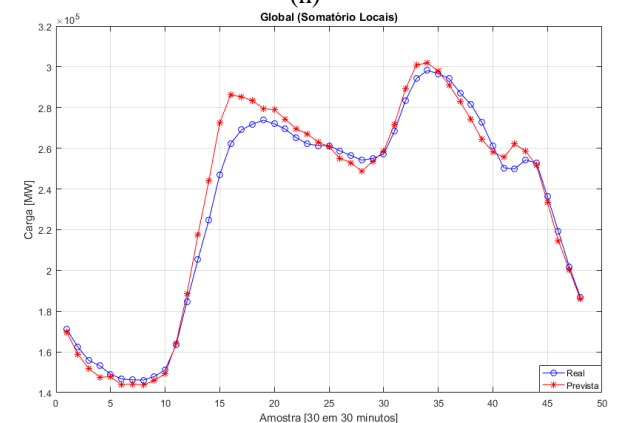
(g)



(h)



(i)



(j)

Fonte: Resultado da pesquisa

Os testes realizados baseados na terceira metodologia podem ser considerados promissores, cuja maioria das subestações, mais precisamente 89%, teve um MAPE abaixo de 5%. Somente a subestação de Hinuera obteve o MAPE fora da faixa aceitável. E o mais importante é que o somatório das locais previstas que resulta na global teve um MAPE melhor do que o previsto no sistema previsor global. Há um destaque também para o resultado da subestação Kopu que teve o melhor MAPE entre todas as metodologias propostas.

## 6.5 RESULTADOS DA QUARTA METODOLOGIA

### 6.5.1 Análise do MAPE da Quarta Metodologia

A metodologia proposta ainda é um sistema “embrionário” que está sendo desenvolvido. Porém, alguns resultados promissores já foram auferidos. Na Tabela 9 mostram-se os valores do MAPE das cargas locais obtidos com a aplicação desta metodologia.

Tabela 9 - MAPE das cargas locais

Subestação	MAPE (%)			Tempo de Processamento (s)
	Individuais	Agregada 1	Agregada 2	
Waihou	4,59	4,59	4,59	59,52
Cambridge	2,63	2,63	2,63	59,40
Hamilton 33kV	1,84	1,84	1,84	59,61
Hamilton 11kV	4,51	4,51	4,51	61,41
Te Awamutu	3,45	3,45	3,45	58,96
Kopu	12,69	4,69	5,08	59,94
Waikino	16,27			61,09
Hinuera	18,69	60,18		
Kinleith	9,49	9,49	61,71	
Global (somatório das locais)	0,70	0,63	0,61	0,005

Fonte: Resultado da pesquisa


Na segunda coluna da Tabela 9, são relacionados os valores dos MAPE individuais de cada uma das subestações. Porém, os resultados das subestações Kopu, Waikino, Waihou e Kinleith não foram tão satisfatórios. Por esta razão, propõe-se agregar, primeiramente, as subestações Kopu, Waikino e Hinuera que resultou um MAPE menor. Uma segunda proposta de agregação compreende agrupar as subestações Kopu, Waikino, Waihou e Kinleith, que resultou em um MAPE de melhor qualidade.


Ao observar o MAPE do somatório do valor de carga prevista (previsão global) de cada subestação percebe-se uma melhora no valor do MAPE global, o que evidencia um resultado muito expressivo para o setor de energia elétrica.

### 6.5.2 Análise Gráfica das Curvas de Cargas Previstas e Reais da Quarta Metodologia


Uma análise gráfica, também, foi realizada para se inferir sobre o comportamento da carga. A curva com traçado azul corresponde a carga real, enquanto que no traçado na cor vermelha representa a curva de carga prevista. O conjunto ilustrado na Figura 21 corresponde às curvas das cargas locais, sendo: (a) Subestação Kopu, (b) Subestação Waikino, (c) Subestação Waihou, (d) Subestação Cambridge, (e) Subestação Hamilton 11kV, (f) Subestação Hamilton 33kV, (g) Subestação Te Awamutu, (h) Subestação Hinuera, (i) Subestação Kinleith, (j) Somatório das cargas locais, (k) Agregada 1 (Kopu, Waikino e Hinuera) e (l) Agregada 2 (Kopu, Waikino, Hinuera e Kinleith).

Figura 21 - Curvas de cargas locais provenientes da quarta metodologia







(e)




(f)




(g)




(h)




(i)



(j)



(k)



(l)

Fonte: Resultado da Pesquisa.



## 6.6 COMENTÁRIOS

Neste capítulo, foram apresentados os resultados da previsão de carga multinodal realizada considerando-se os dados históricos de uma companhia do setor elétrico da Nova Zelândia (CDS, 2010).

As metodologias propostas no Capítulo 5 foram testadas e analisadas, usando-se a métrica de inferência MAPE e da análise da curva de carga real e prevista visando avaliar o desempenho da metodologia. Conclui-se, após exaustivos experimentos, que as três primeiras metodologias propostas apresentaram uma melhoria muito significativa para a maioria das subestações analisadas e, com um tempo de processamento médio de 21 segundos, que por sinal é um tempo relativamente pequeno perto da janela temporal que está sendo prevista (24 horas). Portanto, de um modo geral as três metodologias apresentaram desempenho superior (tempo de processamento e MAPE) em relação às principais arquiteturas disponíveis na literatura especializada.

A metodologia alternativa proposta, no intuito de obter a qualidade das soluções e a rapidez das respostas, foi testada e analisada nas mesmas condições usadas nas outras metodologias. Conforme se pode observar, a técnica utilizada produziu resultados satisfatórios. Porém, o tempo de processamento (média 60 segundos) foi relativamente maior do que o tempo da rede ARTMAP-*Fuzzy* convencional. No entanto, por ser inovadora a proposta de treinamento reverso, necessita de ajustes na estrutura deste novo algoritmo para que o casamento das categorias ocorra de forma mais rápida, *i.e.*, foi observado que o número de ocorrências do *reset* no módulo ARTb incrementa a cada novo padrão apresentado para o treinamento da rede e, isso faz com que o processo de treinamento seja mais lento.

## 7 CONCLUSÕES

### 7.1 CONSIDERAÇÕES FINAIS

Prever a carga a ser gerada no setor de energia elétrica é uma tarefa de muita utilidade para o mercado de energia e encontrar uma ferramenta capaz de fazer isso de forma eficaz e rápida é um dos principais objetivos dos pesquisadores dessa área. A utilização das redes neurais artificiais tem sido uma das principais ferramentas utilizadas pelos pesquisadores, por ser tratar de uma técnica inteligente que possui a habilidade de aprender e generalizar o conhecimento adquirido sem grandes formulações teóricas ou de uma modelagem prévia da carga como é realizado nos procedimentos estatísticos.

Uma das redes neurais artificiais que tem ganhado espaço em muitas pesquisas é a rede ARTMAP-*Fuzzy*, por se tratar de uma rede que foi criada para solucionar o dilema da estabilidade e da plasticidade (aprender novos padrões sem perder as características aprendidas anteriormente), esta característica se dá pelo teste de vigilância que existe na estrutura da rede. Essa rede tem sido muito utilizada no reconhecimento de padrões, processamento de imagens, controle, otimização, diagnósticos e previsões. Outra rede muito utilizada em previsões é a *backpropagation* ela é benchmark em previsões, porém ela possui alguns problemas de convergência. Dentre as redes neurais artificiais a rede ARTMAP-*Fuzzy* foi a rede escolhida para o desenvolvimento deste trabalho por sua simplicidade e a capacidade de realizar previsões de forma confiável e rápida.

Esta pesquisa de doutorado teve por objetivo o desenvolvimento de uma metodologia para realizar previsões de cargas elétricas em nível desagregado, *i.e.*, previsão multinodal. No decorrer da pesquisa, surgiram algumas propostas que fizeram com que ela fosse dividida em quatro metodologias. Todas as metodologias foram baseadas na RNA ARTMAP-*Fuzzy*. Porém, com algumas modificações, a primeira metodologia foi dividida em dois métodos. O primeiro método constitui-se na utilização de uma RNA ARTMAP-*Fuzzy* combinada com o emprego de um módulo corretor *Pro Rata* durante a fase de previsão da RNA multinodal. Ou seja, à medida que for executada a previsão, em cada instante, aplicou-se o CPR. O segundo método, que possui a mesma arquitetura do primeiro método, porém, a diferença refere-se à aplicação do CPR que é executada somente após a conclusão da previsão multinodal pela RNA. Os resultados desses procedimentos foram comparados entre si e com a previsão sem a

interferência do CPR. Então, pode-se concluir que algumas previsões foram melhoradas, Porém, vale ressaltar que o corretor proposto (CPR) ainda é uma proposta incipiente, a qual pode ser bastante aprimorada.

Na segunda metodologia proposta, baseou-se em dividir as subestações por regiões tentando preservar algumas características como, por exemplo: climáticas, relevo, aspectos físicos e socioeconômicos. Utilizando a proposta do sistema previsor, foi adaptado outro sistema previsor chamado de sistema previsor regional entre o sistema previsor global e o sistema previsor local. Por meio dos testes realizados, percebeu-se que 45% das subestações obtiveram resultados significativos (redução do erro), 33% ficaram com seus MAPE entre 5 e 6 por cento, e apenas 22% não tiveram MAPES expressivos. Contudo, esses valores podem ser melhorados com outras alterações como, por exemplo, melhorar a composição da entrada da RNA.

A terceira metodologia foi realizada alterando as entradas da RNA ARTMAP-*Fuzzy* inserido apenas os FPCG com um janelamento de três cargas Este procedimento gerou resultados significativos. Ao realizar todos estes testes pode-se perceber alguns fatores que melhoram e outros nem tanto a previsão de carga local. Porém, no âmbito global quando são somadas as cargas locais, observa-se uma melhoria muito significativa nos resultados.

Estendendo esta pesquisa, propôs-se uma nova abordagem que visa proporcionar resultados com precisões similares ou melhores às metodologias, apresentadas nesta pesquisa (três versões), bem como às principais metodologias encontradas na literatura especializadas. Esta nova proposta, designada RNA ARTMAP-*Fuzzy* Reversa (AMORIM *et al.*, 2019), foi aplicada no contexto do previsor multinodal. Trata-se, basicamente, da execução de apenas dois módulos da RNA ARTMAP-*Fuzzy*, *viz.*, os módulos inter-ART e ARTb em cada barra considerada do sistema. Isto foi possível, mediante o uso de janelas com a mesma composição da entrada e o aproveitado do aprendizado adquirido pelo módulo ARTa por ocasião do treinamento relativo à previsão global. Ou seja, considerou-se que a RNA ARTa, durante o treinamento (na previsão global), já adquiriu o conhecimento necessário e suficiente para alimentar as RNAs individuais. Neste caso, pode-se, também, aplicar a CPR.

Os primeiros testes realizados, considerando-se esta nova proposta, indicam que se trata de uma metodologia promissora. Por ser uma proposta incipiente, há a necessidade de inserção de melhorias baseadas numa melhor compreensão do seu funcionamento e a realização de exaustivos testes. Em caráter geral, podem-se destacar os seguintes benefícios:

- Preservação das características de plasticidade e de estabilidade;
- Processamento paralelo dos módulos locais;
- Redução do tempo de processamento dos módulos;
- Dados de entrada comum aos módulos locais;
- Aplicação em sistemas de médio e grande porte;
- Qualidade nas previsões. (a ser aperfeiçoado)

## 7.2 SUGESTÕES PARA TRABALHOS FUTUROS

O trabalho desenvolvido nessa pesquisa produziu resultados satisfatórios. Consideram-se resultados satisfatórios, tendo em vista à rapidez, algo muito superior ao que se observa em relação aos resultados correlatos disponíveis na literatura, assim como em razão de proporcionar um índice MAPE muito próximo ou inferior a 5% atendendo plenamente às exigências do setor elétrico.

Como sempre, pode-se explorar mais possibilidades. Aqui ficam algumas sugestões para futuras pesquisas.

- Estudar e implementar possibilidades de melhoria no corretor *Pro Rata*, desenvolvendo, por exemplo, um conjunto de regras *fuzzy* que visa melhorar a correção da previsão durante a fase de previsão ou ao final da fase de previsão da rede.
- Trocar a rede ARTMAP-*Fuzzy* por outra rede, por exemplo, a rede ARTMAP Euclidiana.
- Alterar o janelamento de cargas elétricas e inserir, se possível, mais informações de entrada na rede, como, por exemplo, a temperatura, se é feriado ou não, horário de verão e outras informações que poderão contribuir para a melhoria da qualidade das previsões de carga.
- Na nova estrutura da rede denominada ARTMAP-*Fuzzy* Reversa realizar o incremento do parâmetro  $\rho_b$ , para verificar melhorias na saída da rede. Também, explorar outras possibilidades que podem produzir melhores resultados, principalmente em relação à exatidão.

## REFERÊNCIAS

- ABREU, T.; AMORIM, J., A; SANTOS-JUNIOR, R., C; LOTUFO, D. P. A.; MINUSSI, R. C. Multinodal load forecasting for distribution systems using a *fuzzy-artmap* neural network. **Applied Soft Computing**, Amsterdam, v. 71, p. 307-316, 2018.
- AHMED, M.A.; REDDY, K.S.; PRAKASH, J.; RAI, A; SINGH, B.P. Statistical analysis of load and its frequency response for load forecasting in a medium voltage distribution system. *In: INTERNATIONAL CONFERENCE ON ENERGY, COMMUNICATION, DATA ANALYTICS AND SOFT COMPUTING (ICECDS)*, 2017, Chennai. **Proceedings [...]** [S. l.: s. n.], 2017. p. 1146-1149. Doi: 10.1109/ICECDS.2017.8389621.
- ALTRAN, A. B. **Sistema inteligente para previsão de carga multinodal em sistemas elétricos de potência**. 2010. 87 f. Tese (Doutorado em Engenharia Elétrica) - Departamento de Engenharia Elétrica, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2010.
- AL-KANDARI, A. M.; SOLIMAN, S. A.; EL-HAWARY, M. E. *Fuzzy* short term electric load forecasting. **Electric Power & Energy Systems**, [s. l.], v. 26, n. 2, p. 111-122, 2004.
- AMORIM, J. A.; ABREU, T; TONELLI-NETO, M.; MINUSSI, C. R. A new formulation of the multinodal load forecasting based on adaptive resonance theory with reverse training. **Electric power Systems Research Journal**, Amsterdam, 2019. no prelo.
- AMORIM, D. G. **Redes ART com Categorias Internas de Geometria Irregular**. 2006. 352 f. Tese (Doutorado em Física, Área da Ciência e Computação e Inteligência Artificial) - Universidade de Santiago de Compostela - USC, Santiago de Compostela, 2006.
- BOHLIN, T. P. **Practical grey-box process identification: theory and applications**. New York: Springer, 2006.
- BOX, G. E.; JENKINS, G. M. **Time series analysis: forecasting and control**. Holden-Day: San Francisco, 1976.
- CARPENTER, G. A; GROSSBERG, S. The ART of Adaptive Pattern Recognition by a Self-Organizing Neural Network. **Computer**, Pistacaway, v. 21, n. 3, p. 77-88, 1988.
- CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: supervised real-learning and classification of non-stationary data by a self-organizing neural network. **Neural Network**, New York, v. 4, n. 5, p. 565-588, 1991<sub>a</sub>.
- CARPENTER, G. A.; GROSSBERG, S. and ROSEN D. B. *Fuzzy* ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. **Neural Network**, New York, v. 4, n. 1, p. 759-771, 1991<sub>b</sub>.
- CARPENTER, G. A. and GROSSBERG, S. A self-organizing neural network for supervised learning, recognition and prediction. **IEEE Communications Magazine**, Pistacaway, v. 30, n. 9, p. 38-49, 1992.

CARPENTER, G. A.; GROSSBERG, S. **Adaptive resonance theory, encyclopedia of machine learning and data mining**. London: Springer, 2016. Doi: [https://doi.org/10.1007/978-1-4899-7502-7\\_6-1](https://doi.org/10.1007/978-1-4899-7502-7_6-1).

CARPENTER, G. A.; GROSSBERG, S.; MARKUZON, N.; REYNOLDS, J. H.; ROSEN, D. B. *Fuzzy* ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Networks**, New York, v. 3, n. 5, p. 698-713, 1992.

CARPENTER, G. A.; ROSS, W. D. ART-EMAP: A neural network architecture for object recognition by evidence accumulation. **IEEE Transactions on Neural Networks**, New York, v. 6, n. 4, p. 805-818, 1995.

CDS-Centralized Dataset. **Electricity commission for the load dataset**. New Zealand, 2010.

CHEN, C. S.; TZENG, Y. M.; HWANG, J. C. The application of artificial neural networks to substation load forecasting. **Electric Power Systems Research**, Amsterdam, v. 38, p. 153-160, 1996.

GEORGIOPOULOS, M.; FERNLUND, H.; BEBIS, G.; HEILEMAN, G. L. Order of search in *fuzzy* ART and *fuzzy* ARTMAP: Effect of the choice parameter. **Neural Networks**, New York, v. 9, n. 9, p. 1541-1559, 1996.

GROSS, G.; GALIANA, F. D. Short term load forecasting. **Proceedings of the IEEE**, New York, v. 75, n. 12, p. 1558-1573, 1987.

GROSSBERG, S. Adaptive pattern classification and universal recoding, I: parallel development and coding of neural feature detectors. **Biological Cybernetics**, Heidelberg, v. 23, n. 3, p. 121-134, 1976.

HANDSCHIN, E.; DÖRNEMANN, C. Bus load modeling and forecasting. **IEEE Transactions on Power Systems**, Piscataway, v. 3, n. 2, p. 627-633, 1988. Doi: [10.1109/59.192915](https://doi.org/10.1109/59.192915).

HAYKIN, S. **Neural networks and learning machines**. 3rd ed. New Jersey: Prentice-Hall, 2008.

HEBB, D. O. **The organization of behavior: a neuropsychological theory**. New York: Wiley, 1949. 335 p.

HIPPERT, H. S.; PEDREIRA, C. E.; SOUZA, R. C. Neural networks for shortterm load forecasting: A review and evaluation. **IEEE Transactions on Power Systems**, New York, v. 16, n. 1, p. 44-55, 2001.

KEYVAN, S.; SONG, X.; KELLY, M. Nuclear fuel pellet inspection using artificial neural networks. **Journal of Nuclear Materials**, v. 264, n. 1-2, p.141-154, 1999.

KOHONEN, T. **Self-organizing and associative memory**. 2nd ed. Berlin: Springer-Verlag, 1987.

LAMBERT-TORRES, G.; BORGES DA SILVA, L. E.; VALIQUETTE, B.; GREISS, H.; MUKHEDKAR, D. A *fuzzy* Knowledge-based system for bus load forecasting. **IEEE International Conference on Fuzzy Systems**, San Diego, p. 1211-1218, 1992.

LIAO, G.-C.; TSAO, T.-P. Application of *fuzzy* neural networks and artificial intelligence for load forecasting. **Electric Power Systems Research**, Amsterdam, v. 70, n. 3, p. 237-244, 2004.

LIM, C. P.; HARRISON, R. F. Modified *fuzzy* ARTMAP approaches bayes optimal classification rates: an empirical demonstration. **Neural Networks**, New York, v. 10, n. 4, p. 755-774, 1997.

LIU, K.; SUBBARAYAN, S.; SHOULTS, R. R.; MANRY, M. T.; KWAN, C.; LEWIS, F. L.; NACCARINO, J. Comparison of very short-term load forecasting techniques. **IEEE Transactions on Power Systems**, New York, v. 11, n. 2, p. 877- 882, 1996.

LOPES, M. L. M. **Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica**. 2005. 149 f. Tese (Doutorado) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2005.

MALKI, H. A.; KARAYIANNIS, N. B.; BALASUBRAMANIAN, M. Short-term electric power load forecasting using feedforward neural networks. **Expert Systems**, New York, v. 21, n. 3, p. 157-167, 2004.

MCCULLOCH, W. S.; PITTS, W. A. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysic**, New York, v. 5, p. 115-133, 1943.

METAXIOTIS, K.; KAGIANNAS, A.; ASKOUNIS, D. and PSARRAS, J. Artificial intelligence in short term electric load forecasting: A state-of-the-art survey for the researcher. **Energy Conversion and Management**, London, v. 44, n. 9, p.1525-1534, 2003.

MINSK, M.; PAPERT, S. **Perceptrons: an introduction to computational geometry**. Cambridge: MIT, 1969.

MOGHRAM, I.; RAHMAN, S. Analysis and evaluation of five short-term load forecasting techniques. **IEEE Transactions on Power Systems**, New York, v. 4, n. 4, p. 1484-1491, 1989.

MURTO, P. **Neural network models for short-term load forecasting**. 1998. Masters (Thesis) - Department of Engineering Physics and Mathematics, Helsinki University of Technology, 1998.

MÜLLER, M. R. **Análise de desempenho da rede neural artificial ARTMAP-Fuzzy aplicada para previsão Multi-Step de cargas elétrica em diferentes níveis de agregação**. 2018. 97 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2018.

NOSE-FILHO, K. LOTUFO; A. D. MINUSSI; C. R. Short-term multinodal load forecasting using a modified general regression neural network. **IEEE Transactions on Power Delivery**, New York, v. 26, n.4, p. 2862-2869. October 2011.

O'DONOVAN, T. M. Short term forecasting: an introduction to the Box-Jenkins approach. New York: John Wiley & Sons, 1983.

PARK, D. C.; EL-SHARKAWI, M. A.; MARKS II, R. J.; ATLAS, E.; DAMBORG, M. J. Electric Load Forecasting Using an Artificial Neural networks. **IEEE Transactions on Power Systems**, New York, v. 6, n. 2, p. 442-449, 1991.

PEARSON, K. On-lines and planes of closest fit to systems of points in space. **Philosophical Magazine**, Abingdon, v. 2, n. 11, p. 559–572, 1901.

ROSENBLATT, F. **Principles of neurodynamics**. New York: Spartan Books, 1962.

SAINI, L. M.; SONI, M. K. Artificial neural network based peak load forecasting using Levenberg-Marquardt and Quasi-Newton methods. **IEEE Proceedings on Generation, Transmission & Distribution**, New York, v. 149, n. 5, p. 578- 584, 2002.

SALGADO, R. M.; OHISHI, T.; BALLINI, R. A short-term bus load forecasting system. In: INTERNATIONAL CONFERENCE ON HYBRID INTELLIGENT SYSTEMS (HIS), 10th, Atlanta. **Proceedings [...]** [S. l.: s. n.], 2010. p. 55-60.

SPECHT, D. F. A general regression neural network. **IEEE Transactions on Neural Network**, New York, v. 2, n. 6, p. 568–576, 1991.

STOTT, B. Power system dynamic response calculations. **Proceedings of the IEEE**, v. 67, n. 2, p. 219-241, 1979. Doi: 10.1109/PROC.1979.11233.

SWARUP, K. S.; SATISH, B. Integrated ANN approach to forecast load. **IEEE Computer Applications in Power**, New York, v. 15, n. 1, p. 46-51, 2002.

TORKZADEH, R.; MIRZAEI, A.; MIRJALILI, M. M.; ANARAKI, A. S.; SEHHATI, M. R. AND BEHDAD, F. Medium term load forecasting in distribution systems based on multi linear regression & principal component analysis: a novel approach. In: CONFERENCE ON ELECTRICAL POWER DISTRIBUTION NETWORKS (EPDC), 19th, 2014, [s. l.]. **Proceedings [...]** [S. l.: s. n.], 2014. p. 66-70. Doi: 10.1109/EPDC.2014.6867500.

TRANSPower TRANSMISSION NETWORK. 2018. Disponível em: <https://www.transpower.co.nz/keeping-you-connected/maps-and-gis-data/maps-and-gis-data> Acesso em: 24 nov. 2018.

VILLALBA, S. A.; BEL, C.A. Hybrid demand model for load estimation and short term load forecasting in distribution electric systems. **IEEE Transactions on Power Delivery**, New York, v. 15, n. 2, p. 764-769, 2000.

VON DER MALSBERG, C. Self-organization of orientation sensitive cells in the striate cortex. **Biological Cybernetics**, Heidelberg, v. 14, n. 2, pp 85-100, 1973.

VAN-CUTSEM, T.; VOURNAS, C. **Voltage stability of electric power systems**. Heidelberg: Springer, 2007.



VON NEUMANN, J. **The computer and the brain**. New Haven: Yale University Press, 1958.

WERBOS, P. J. **Beyond regression: new tools for prediction and analysis in the behavioral sciences**. 1974. Master (Thesis) - Harvard University, Harvard, 1974.

WILLIAMSON, J. Gaussian ARTMAP: a neural network for fast incremental learning of noisy multidimensional maps. **Neural Networks**, Kidlington, v. 9, n. 5, p. 881-897, 1996.

WU, L.; YUAN, J. S.; ZHU, Y. L. Mis-based long term distribution load forecasting system. *In*: INTERNATIONAL CONFERENCE ON ADVANCES IN POWER SYSTEM CONTROL, OPERATION AND MANAGEMENT ASDCOM, 6., 2003, [s. n.]. **Proceedings** [...] [S. l.: s. n.], 2003. v. 2, p. 880-883. Doi: 10.1049/cp:20030703.

YOO, C.; IM, J.; PARK, S.; QUACKENBUSH, L. J. Estimation of daily maximum and minimum air temperatures in urban landscapes using modis time series satellite data. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 137, p. 149–162, 2018. <https://doi.org/10.1016/j.isprsjprs.2018.01.018>.

ZADEH, L. Fuzzy sets. **Information and Control**, Maryland Heights, v. 8, p. 338-353, 1965.

## ARTIGOS PUBLICADOS

AMORIM, J. A.; MINUSSI, R. C.; LOPES, M. L. M. **Previsão de carga multinodal a curto prazo utilizando redes neurais artificiais.** XXXVII CONGRESSO NACIONAL DE MATEMÁTICA APLICADA E COMPUTACIONAL (CNMAC 2017), Set. 19-22, 2017, São José dos Campos - SP, Brasil.

AMORIM, J. A.; ABREU, T; MINUSSI, R. C. **Multinodal Load Forecasting based on a Fuzzy-ARTMAP Neural Network.** In: XII LATIN-AMERICAN CONGRESS ON ELECTRICITY GENERATION AND TRANSMISSION (CLAGTEE 2017), Nov. 12th - 15th, Mar del Plata, Argentina, 2017.

ABREU, T; AMORIM, J, A; SANTOS-JUNIOR, R, C; LOTUFO, D, P, A; MINUSSI, R, C. **Multinodal load forecasting for distribution systems using a *fuzzy-artmap* neural network.** Applied Soft Computing. 2018, v. 71, p. 307-316.

## ARTIGO SUBMETIDO

AMORIM, J.A; ABREU, T; TONELLI-NETO, M; MINUSSI, C.R. **A new formulation of the multinodal load forecasting based on adaptive resonance theory with reverse training.** Electric Power Systems Research, 2019.