

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA
CAMPUS DE ILHA SOLTEIRA**

JOAQUIM RIBEIRO MOREIRA JÚNIOR

**PREVISÃO DE CARGAS MULTINODAIS REALIZADA ATRAVÉS DA ANÁLISE
DA PREVISÃO DE CARGAS ELÉTRICAS AGREGADAS VIA REDE NEURAL
*ARTMAP FUZZY***

**Ilha Solteira
2020**

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

JOAQUIM RIBEIRO MOREIRA JÚNIOR

**PREVISÃO DE CARGAS MULTINODAIS REALIZADA ATRAVÉS DA ANÁLISE
DA PREVISÃO DE CARGAS ELÉTRICAS AGREGADAS VIA REDE NEURAL
ARTMAP FUZZY**

Dissertação apresentada à Faculdade de Engenharia de Ilha Solteira – UNESP – Campus de Ilha Solteira, como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.

Área de conhecimento: Automação.

Prof. Dra. Mara Lúcia Martins Lopes
Orientadora

Prof. Dra. Thays Aparecida de Abreu Silva
Colaboradora

FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

M838p Moreira Júnior, Joaquim Ribeiro.
Previsão de cargas multinodais realizada através da análise da previsão de
cargas elétricas agregadas via rede neural ARTMAP Fuzzy / Joaquim Ribeiro
Moreira Júnior. -- Ilha Solteira: [s.n.], 2020
74 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de
Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2020

Orientador: Mara Lúcia Martins Lopes
Inclui bibliografia

1. Redes neurais artificiais. 2. Fator de participação de carga global. 3.
Previsão de cargas multinodal. 4. ARTMAP Fuzzy.


Raiane da Silva Santos

Supervisora Técnica de Seção
Seção Técnica de Referência, Atendimento ao usuário e Documentação
Diretoria Técnica de Biblioteca e Documentação
CSUB - 9999



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Ilha Solteira

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Previsão de cargas multinodais realizada através da análise da previsão de cargas elétricas agregadas via rede neural Artmap Fuzzy

AUTOR: JOAQUIM RIBEIRO MOREIRA JUNIOR

ORIENTADORA: MARA LUCIA MARTINS LOPES

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

Prof. Dr. MARA LUCIA MARTINS LOPES

Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. CARLOS ROBERTO MINUSSI

Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. KENJI NOSE FILHO

Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas / Universidade Federal do ABC - UFABC

Ilha Solteira, 05 de agosto de 2020

DEDICATÓRIA

A Deus,
Aos meus pais, Edi e Joaquim.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por me fortalecer nos momentos difíceis, por ter me guiado nesta trajetória e por proporcionar anjos que me auxiliaram e me ensinaram a manter a calma em todos os momentos.

Agradeço aos meus pais Edi e Joaquim, pela confiança em mim depositada, ao incentivo e apoio na minha tomada de decisão; à minha irmã Andreia, por todo carinho, por sempre acreditar em mim e por ser a base de nossa família; aos meus sobrinhos Kauã, Marcos e Heloisa por me proporcionar momentos de alegrias e motivação. Agradeço a todos os entes familiares que, de algum modo, estiveram em orações e me incentivaram.

Agradeço à minha orientadora, Prof.^a Dra. Mara Lucia Martins Lopes, pela dedicação, pela confiança, pela amizade, por ser uma pessoa iluminada, por me ensinar e me acalmar nos momentos difíceis (que não foram poucos).

Agradeço à minha Coorientadora Prof.^a Dra. Thays Aparecida de Abreu Santos, pela amizade desde a universidade, por ter me auxiliado e incentivado a participar do programa de pós graduação, por ser a idealizadora do projeto de pesquisa e por todo o suporte nesta trajetória.

Agradeço aos meus amigos de estudos, Ali, Aline, Bruno Coelho, Dijiane, Jusiane, Tânia e Thiago Garcia, por estarem me apoiando e ter compartilhado comigo seus ensinamentos.

Aos meus amigos e companheiros do laboratório SINTEL que compartilharam suas experiências, vivências e o cafezinho da tarde, em especial a Priscila B. A. Oliveira, por me auxiliar a trabalhar com o Matlab.

Aos meus amigos Hiago Bolato, Solange Mitie, Josiane Prado, Leonardo Prado, Michele Pessoa, Karine, Marcos e todos os meus colegas de trabalho por terem me apoiado, incentivado e suportado todos os bons momentos e os difíceis também.

Agradeço a todas as pessoas que de alguma forma colaboraram, contribuíram e me apoiaram na realização deste trabalho.

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

Muito obrigado.

“A persistência é o caminho do êxito”.
Charles Chaplin.

RESUMO

Na contemporaneidade, a previsão de cargas é de suma importância para a otimização da geração e distribuição de energia elétrica, uma vez que a previsão garante maior confiabilidade e economia para esse processo, definindo quando e quanto de geração, transmissão e capacidade de distribuição devem ser dispostas para atender à carga esperada sem que haja interrupções em seu fornecimento. O presente trabalho tem por objetivo analisar diversas agregações de cargas elétricas em subestações de sistemas de distribuição de energia elétrica, visando à melhoria na previsão de cargas multinodais, (em vários pontos de interesse da rede elétrica) também conhecida como carga por barramento, a qual considera os diferentes tipos de consumidores (industriais, comerciais e residenciais). Para realizar a previsão multinodal, foi utilizada a rede neural ARTMAP *Fuzzy*, que é baseada na Teoria da Ressonância Adaptativa (ART), e que possui características essenciais para o funcionamento e a obtenção de resultados de uma rede neural artificial. Essas características são baseadas no Dilema da Estabilidade e Plasticidade, o qual é capaz de aprender novos conhecimentos (estabilidade), sem perder as informações previamente adquiridas (plasticidade), auxiliando assim em soluções rápidas e precisas. A metodologia foi desenvolvida em quatro partes, sendo elas: (i) realizar a previsão das cargas globais; (ii) prever os fatores de participação de cada subestação e em seguida realizar a previsão das cargas locais; (iii) estudar e identificar as possíveis agregações das cargas multinodais (subestações) realizadas, visando à melhoria da previsão de carga multinodal e carga global e (iv) por meio das agregações das subestações efetuadas, realizar a previsão de carga multinodal referente ao bloco de subestações agregadas, visando prever as cargas das subestações individuais. A metodologia foi desenvolvida no software MATLAB e foram utilizados dados referentes a um subsistema de distribuição de energia elétrica da Nova Zelândia, composto por nove Subestações, para prever cargas de 24 horas à frente. Como forma de avaliar os resultados obtidos pela previsão, foi utilizado o erro percentual médio absoluto - MAPE (Mean Absolute Percentage Error).

Palavras-chave: Redes neurais artificiais. Fator de participação de carga global. Previsão de cargas multimodal. ARTMAP *Fuzzy*.

ABSTRACT

Currently, load forecasting is of paramount importance to optimize the generation and distribution of electric energy, since the forecast guarantees greater reliability and savings for this process, defining when and how much of generation, transmission and distribution capacity should be arranged to meet the expected load without interruptions in its supply. The present work aims to analyze several aggregations of electric loads in substations of electric power distribution systems aiming to improve the forecast of multinodal loads, (in several points of interest of the electric network) also known as load per bus, which considers the different types of consumers: industrial, commercial and residential. To perform the multinodal forecast, the neural network ARTMAP *Fuzzy* was used, which is based on the Adaptive Resonance Theory (ART), and which has essential characteristics for the functioning and results of an artificial neural network. These characteristics are based on the dilemma of stability and plasticity that guarantees fast and accurate solutions. The methodology was developed in four parts: (i) to forecast the global loads; (ii) to predict the participation factors of each substation and then perform the forecast of local loads; (iii) to study and identify the possible aggregations of multinodal loads (substations) carried out in order to improve the forecast of multinodal and global loads and (iv) through the aggregations of the substations carried out, forecast the multinodal load for the aggregated substations block in order to forecast the loads of the individual substations. The methodology was developed in the MATLAB software and data from a New Zealand electricity distribution subsystem, composed of nine substations, were used to forecast 24-hour ahead loads. As a way of evaluating the results obtained by the forecast, the mean absolute percentage error - MAPE (Mean Absolute Percentage Error) was used.

Keywords: Artificial neural networks. Global load participation factor. Multinodal load forecast. ARTMAP *Fuzzy*.

LISTA DE FIGURAS

Figura 1 - Mapa da rede de transmissão de energia no norte da Ilha de Nova Zelândia.....	23
Figura 2 - Diagrama Elétrico.	24
Figura 3 - Entrada da RNA para PCG.	26
Figura 4 - Saída da RNA para PCG.....	26
Figura 5 - Entrada da RNA para PCM.	28
Figura 6 - Saída da RNA para PCM.	28
Figura 7 - Entrada da RNA para PCMA.....	30
Figura 8 - Saída da RNA para PCMA.	31
Figura 9 - Entrada da RNA para PMPA.	32
Figura 10 - Saída da RNA para PMPA.....	32
Figura 11 - Curvas de carga elétrica global real e prevista pela rede neural ARTMAP <i>Fuzzy</i>	35
Figura 12 - Curva de Carga elétrica local real e prevista, dada pela a rede neural ARTMAP <i>Fuzzy</i> , das subestações de Kopu, Waikino, Waihou, Hamilton 11, Hamilton 33 e Cambridge.	37
Figura 13 - Curva de carga elétrica local real e prevista, dada pela a rede neural ARTMAP <i>Fuzzy</i> , das subestações de Te Awamutu, Hinuera e Kinleith.	38
Figura 14 - Curvas de carga elétrica global real e prevista pela rede neural ARTMAP <i>Fuzzy</i> através da soma das previsões de cargas multinodais.	39
Figura 15 - Previsão da carga agregada real e carga agregada prevista pela rede ARTMAP <i>Fuzzy</i> para análise 1.	40
Figura 16 - Previsão da carga agregada real e carga agregada prevista pela rede ARTMAP <i>Fuzzy</i> para análise 2 para os blocos agregados: a) Waikino e Waihou e b) Hamilton 11, Kopu, Hinuera e Kinleith.	42
Figura 17 - Previsão da carga agregada real e carga agregada prevista pela rede ARTMAP <i>Fuzzy</i> para análise 3 para os blocos agregados: a) Kopu, Waikino e Hamilton 11, b) Cambridge e Hinuera e c) Te Awamutu e Kinleith.....	43
Figura 18 - Previsão da carga agregada real e carga agregada prevista pela rede ARTMAP <i>Fuzzy</i> para análise 4 para os blocos agregados: a) Kopu, Waikino e Hinuera e b) Hamilton 11, Cambridge e Kinleith.....	45

Figura 19 - Previsão da carga agregada real e carga agregada prevista pela rede ARTMAP <i>Fuzzy</i> para análise 5 para os blocos agregados: a) Hamilton11, Cambridge e Kinleith e b) Waikino, Te Awamutu e Hamilton 33.	46
Figura 20 - Previsão da carga agregada real e carga agregada prevista pela rede ARTMAP <i>Fuzzy</i> para análise 6 para os blocos agregados: a) Hamilton 11, Hamilton 33 e Cambridge e b) Waikino, Hinuera e Kinleith.....	47
Figura 21 - Previsão da carga agregada real e carga agregada prevista pela rede ARTMAP <i>Fuzzy</i> para análise 7 para os blocos agregados: a) Hamilton 11, Hamilton 33 e Cambridge e b) Waikino, Hinuera e Kinleith.....	48
Figura 22 - Curvas de carga elétrica local real, prevista com retorno e prevista sem retorno para análise 5.	51
Figura 23 - Curvas de carga elétrica global real e prevista pela rede neural ARTMAP <i>Fuzzy</i> através da soma das previsões de cargas multinodais via análise 5.	52
Figura 24 - Curvas de carga elétrica local real, prevista com retorno e prevista sem retorno para análise 6.	54
Figura 25 - Curvas de carga elétrica global real e prevista pela rede neural ARTMAP <i>Fuzzy</i> através da soma das previsões de cargas multinodais via análise 6.	55
Figura 26 - Curvas de carga elétrica local real, prevista com retorno e prevista sem retorno para análise 7.....	57
Figura 27 - Curvas de carga elétrica global real e prevista pela rede neural ARTMAP <i>Fuzzy</i> através da soma das previsões de cargas multinodais via análise 7.	58

LISTA DE TABELAS

Tabela 1 - Especificações dos transformadores de cada subestação.	24
Tabela 2 - Dados exógenos utilizados nos dados de entrada da rede neural ARTMAP <i>Fuzzy</i> .27	
Tabela 3 - Parâmetros da rede neural ARTMAP <i>Fuzzy</i> para previsão global.	35
Tabela 4 - Valores do erro percentual médio absoluto das subestações obtidas através da rede ARTMAP <i>Fuzzy</i>	36
Tabela 5 - Parâmetros da rede neural ARTMAP <i>Fuzzy</i> para previsão das subestações.	36
Tabela 6 - Valores do erro percentual médio absoluto das subestações individuais e agregadas obtidas através da rede ARTMAP <i>Fuzzy</i> para análise 1.	40
Tabela 7 - Valores do erro percentual médio absoluto das subestações individuais e agregadas obtidas através da rede ARTMAP <i>Fuzzy</i> para análise 2.	41
Tabela 8 - Valores do erro percentual médio absoluto das subestações individuais e agregadas obtidas através da rede ARTMAP <i>Fuzzy</i> para análise 3.	42
Tabela 9 - Valores do erro percentual médio absoluto das subestações individuais e agregadas obtidas através da rede ARTMAP <i>Fuzzy</i> para análise 4.	44
Tabela 10 - Valores do erro percentual médio absoluto das subestações individuais e agregadas obtidas através da rede ARTMAP <i>Fuzzy</i> para análise 5.	45
Tabela 11 - Valores do erro percentual médio absoluto das subestações individuais e agregadas obtidas através da rede ARTMAP <i>Fuzzy</i> para análise 6.	47
Tabela 12 - Valores do erro percentual médio absoluto das subestações individuais e agregadas obtidas através da rede ARTMAP <i>Fuzzy</i> para análise 7.	48
Tabela 13 - Parâmetros utilizado para a previsão global da carga agregada.	49
Tabela 14 - Valores do erro percentual médio absoluto das subestações individuais, agregadas e da metodologia proposta para análise 5.	49
Tabela 15 - Valores dos parâmetros da rede neural ARTMAP <i>Fuzzy</i> para realizar o retorno das subestações da análise 5.	51
Tabela 16 - Valores do erro percentual médio absoluto das subestações individuais, agregadas e da metodologia proposta para análise 6.	53
Tabela 17 - Valores dos parâmetros da rede neural ARTMAP <i>Fuzzy</i> para realizar o retorno das subestações da análise 6.	53
Tabela 18 - Valores do erro percentual médio absoluto das subestações individuais, agregadas e da metodologia proposta para análise 7.	55

Tabela 19 - Valores dos parâmetros da rede neural ARTMAP *Fuzzy* para realizar o retorno das subestações da análise 7. 56

LISTA DE SIGLAS E ABREVIATURAS

ARIMA	<i>Auto regressive integrated moving average</i>
ART	Teoria da ressonância adaptativa (<i>Adaptive Ressonance Theory</i>)
CBS	<i>Centralized Dataset</i>
CG	Carga global
CM	Carga multinodal
FCM	<i>Fuzzy C-means</i>
FPCG	Fator de participação da carga global
FPGA	Fator de participação da carga global agregada
FPNCF	Fator de participação da nova carga global
GRNN	Rede neural de regressão generalizada (<i>General Regression Neural Network</i>)
MAPE	Erro percentual absoluto médio (<i>Mean absolute Percentage Error</i>)
MLP	<i>Multilayer perceptron</i>
NCG	Nova carga global
PCG	Previsão de carga global
PCGSS	Previsão da carga global obtida pela soma das subestações
PCM	Previsão de carga multinodal
PCMA	Previsão de carga multinodal agregada
PMPA	Previsão multinodal realizada através das previsões agregadas
PSOM	<i>Pruning Technique Kohonen Self-Organizing Feature Map</i>
RNA	Redes neurais artificiais
SINTEL	Sistemas inteligentes
SOM	Mapa auto-organizável (<i>Self Organizing Maps</i>)
Unesp	Universidade Estadual Paulista

LISTA DE SÍMBOLOS

ART_a	Módulo de entrada
ART_b	Módulo de saída
h	Instantes atuais
$h - 1; h - 2, h - 3$	Instantes passados
CM_j	Carga Multinodal referente ao j-ésimo ponto de interesse
CG	Soma de todas as subestações das Cargas Multinodais.
$FPCG_j$	Fator de Participação da Carga Global referente ao j-ésimo ponto de interesse
$Da(g,d,h)$	Demanda de carga agregada no grupo g no dia d e na hora h;
n	Número de barramentos pertencentes ao grupo g;
$C(i,d,h)$	Carga dos i barramentos pertencentes ao grupo g no dia d e na hora h.
$Sub_i(i, d, h)$	Subestação i, no dia d e na hora h.
$\sum_{i=1}^n C(i, d, h)$	Somatório das cargas no barramento i, no dia d e na hora h;
$PrevTotal$	Soma de todas as cargas;
$PrevLocal_i$	Previsão Local de cada subestação;
n	Número de Subestações.
NA	Número de amostras da série temporal
$C_{real}(t)$	Valor da carga real em relação no tempo t
$C_{prevista}(t)$	Valor da carga prevista no tempo t
A	Entrada de padrões F_1^a em forma de codificação de complemento no módulo ART_a
B	Entrada de padrões F_2^a em forma de codificação de complemento no módulo ART_b
I	Atividade em F_0
β	Taxa de treinamento
ρ_{ab}	Parâmetro de vigilância do módulo inter-ART
ρ_a	Parâmetro de vigilância do módulo ART_a
ρ_b	Parâmetro de vigilância do módulo ART_b
α	Parâmetro de escolha
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 ART_a
F_0^b	Camada que representa o vetor de entrada para o módulo ART_b
F_1^a	Camada de comparação para o módulo ART_a
F_1^b	Camada de comparação para o módulo ART_b
F_2^a	Camada de reconhecimento para o módulo ART_a
F_2^b	Camada de reconhecimento para o módulo ART_b
a	Vetor de entrada do módulo ART_a
$\underline{a}$	Vetor de entrada normalizado
b	Vetor de saída
$\underline{b}$	Vetor de saída normalizado
M	Dimensão dos vetores de entrada na camada F_1
N	Dimensão dos vetores de entrada que na camada F_2 formam as categorias
W	Matriz de pesos
w_j^a	Matriz de pesos do módulo ART_a
w_k^b	Matriz de pesos do módulo ART_b
w_j^{ab}	Matriz de pesos do módulo inter-ART
T_j^a	Função de escolha do módulo ART_a
T_k^b	Função de escolha do módulo ART_b
$\underline{a}_i^c$	Complemento do vetor de entrada do módulo ART_a
$\underline{b}_i^c$	Complemento do vetor de saída do módulo ART_b
y	Vetor de atividade da camada F_2
$\wedge$	Operador AND Fuzzy
J	Categoria ativa (escolhida) para o módulo ART_a
K	Categoria ativa (escolhida) para o módulo ART_b
x	Vetor de atividade em F_1
x^a	Vetor de atividade em F_1^a no módulo ART_a
x^b	Vetor de atividade em F_1^b no módulo ART_b

SUMÁRIO

1	INTRODUÇÃO.....	14
1.1	Organização do Trabalho.....	15
2	PREVISÃO DE CARGAS.....	16
2.1	Variáveis que Influenciam o Comportamento da Carga	17
2.2	Classificação da Previsão de Carga	18
2.3	Métodos para Previsão de Carga	19
2.4	Estado da Arte	19
3	ANÁLISE DA AGREGAÇÃO DE CARGAS ELÉTRICAS DE SUBESTAÇÕES PARA MELHORIA NA PREVISÃO DE CARGA MULTINODAL UTILIZANDO A REDE NEURAL ARTMAP FUZZY.....	22
3.1	Base de Dados	22
3.2	Procedimento de Previsão Multinodal utilizando Cargas Agregadas	24
3.2.1	Previsão de Carga Global (PCG).....	26
3.2.2	Previsão de Carga Multinodal (PCM)	27
3.2.3	Previsão de Cargas Multinodal Agregada (PCMA)	29
3.2.4	Previsão Multinodal realizada através das Previsões Agregadas (PMPA).....	31
4	RESULTADOS.....	34
4.1	Parâmetro de Análise dos Resultados.....	34
4.2	Resultado Obtido para Previsão Global.....	35
4.3	Resultados Obtidos para Previsão Multinodal.....	36
4.4	Resultados Obtidos para Previsão Agregada.....	39
4.5	Resultados da Previsão Multinodal Através do Retorno da Carga Agregada	49
5	CONCLUSÃO.....	59
5.1	Trabalho Publicado.....	60
5.2	Trabalho Aceito	60
5.3	Sugestões para Trabalhos Futuros	60
	REFERÊNCIAS	62
	APÊNDICE A.....	65

1 INTRODUÇÃO

As concessionárias de energia elétrica necessitam ter ciência da demanda de carga elétrica a fim de serem capazes de fornecer aos consumidores energia de forma contínua, econômica e segura, não podendo haver faltas e nem produzir além do estabelecido. Assim, faz-se necessário ter conhecimentos prévios sobre carga elétrica.

A previsão de demanda de cargas elétricas é muito importante para realizar as operações nos sistemas elétricos. Seu conhecimento prévio em nível de carga global e multinodal (barramento, subestações, etc.) faz-se necessário para fornecer energia sem haver interrupções no fornecimento.

Na literatura, existem vários métodos clássicos que são utilizados para obter a previsão de cargas elétricas. Tais métodos são denominados estatísticos e estocásticos, como, por exemplo, o ARIMA de Box-Jenkins (BOX; JENKINS, 1976), modelos de regressão linear (simples ou múltiplo), filtro de Kalman, etc. (MOGHARAM; RAHMAN, 1989). Porém, estes modelos necessitam de modelagem prévia da carga.

No entanto, outros métodos que não se utilizam da modelagem prévia das cargas têm sido abordados nos últimos anos. Tais métodos utilizam técnicas estatísticas ou técnicas baseadas em aprendizado de máquinas (BENDER, 1996; HAYKIN, 2008; ZADEH, 1965), como por exemplo as redes neurais artificiais, lógica *fuzzy*, entre outras.

A maior parte dos trabalhos publicados na literatura realizam a previsão de carga global (RUAS *et al.*, 2004; LOPES, 2005; PANDIAN, *et al.*, 2006; ALVES, 2011; BORDIGNON, 2012; SUGANTHI, 2012; RÊGO, 2016; BARRETO, 2017). No entanto, sem a previsão da carga multinodal é impossível executar qualquer tipo de análise estática ou dinâmica do sistema (ABREU, 2020) (por exemplo: estabilidade do ângulo, fluxo de carga, etc), sendo escassas as publicações para este fim.

Neste trabalho foi desenvolvida uma metodologia para realizar a previsão de cargas elétricas a curto prazo, 24 horas à frente, sendo considerados vários pontos do sistema, como subestações, transformadores e alimentadores. A previsão de carga multinodal é realizada utilizando uma rede neural ARTMAP *Fuzzy* (CARPENTER *et al.*, 1992). Esta RNA é baseada na teoria da ressonância adaptativa (GROSSBERG, 2013), sendo estável para aprender novos conhecimentos e plástica ao não perder as informações já adquiridas.

A metodologia foi desenvolvida em quatro partes: (i) primeiro é realizada a previsão das cargas globais; (ii) são previstos os fatores de participação de cada subestação e, em seguida, são realizadas as previsões das cargas locais; (iii) é realizada uma análise para

identificar as possíveis agregações das cargas multinodais (subestações), visando à melhoria da previsão de carga local e (iv) por meio das agregações das subestações efetuadas, é realizada a previsão de carga multinodal referente ao bloco de subestações agregadas com objetivo de prever as cargas das subestações individuais.

1.1 Organização do Trabalho

Este trabalho é composto por cinco capítulos, sendo descritos da seguinte maneira: “previsão de cargas elétricas”, “metodologia”, “resultados” e finalizando com as “conclusões e sugestões para trabalhos futuros”.

O primeiro capítulo corresponde à introdução do trabalho. O Capítulo 2 aborda a teoria da previsão de cargas elétricas, observando a sua importância para o sistema de energia elétrica, as variáveis que influenciam o comportamento das cargas, bem como a classificação dos tipos de previsões. E, por fim, são apresentados alguns trabalhos que realizaram a previsão de carga elétrica multinodal.

No Capítulo 3 é apresentada a metodologia desenvolvida, por meio da análise da previsão de carga global, previsão de carga multinodal, agregação da carga multinodal e desagregação da carga multinodal.

No Capítulo 4 são mostrados os resultados obtidos pela metodologia proposta, sendo apresentados vários cenários de agregamentos, e analisados os resultados de cada análise proposta.

No Capítulo 5, são apresentadas as conclusões e também, as sugestões para trabalhos futuros.

No Apêndice A é abordada a ferramenta utilizada neste trabalho, a rede neural ARTMAP *Fuzzy* e o seu funcionamento.

2 PREVISÃO DE CARGAS

A energia elétrica é um bem essencial para os seres humanos. Sua forma de produção vem de vários recursos, dependendo da sua região, do recurso predominante do local (se possui água e ar) e da necessidade, além de ser proveniente dos tipos hidrelétrico, eólico, solar, termoelétrico, entre outros. Seu consumo pode ser para residências, indústrias, comércios, entre outras repartições. Para atender à necessidade de energia em cada local, faz-se necessária a elaboração de um planejamento que adapte o sistema de distribuição, pois o mesmo é imprescindível para o sistema elétrico, tanto por conta do seu investimento quanto pelo compromisso na qualidade do serviço que se deve prestar aos consumidores.

As cargas elétricas são constituídas de várias combinações de aparelhos e dispositivos que, quando em conjunto, ajudam a modelar a carga. Num sistema previsor de cargas elétricas é importante conhecer os fatores que influenciam a carga para que se possa ter uma previsão mais precisa e de qualidade.

A previsão de cargas se faz necessária para o sistema de potência por afetar nos preços das tarifas elétricas (VEHVILÄINEN; KEPPO, 2003). Assim, sendo realizada uma previsão precisa, o mercado de energia elétrica consegue melhorar seu sistema de distribuição, atendendo de maneira otimizada as demandas de cada local, minimizando os erros e maximizando os lucros.

Quando se trata de previsão de cargas, em sua maioria, estamos lidando com a previsão de cargas totais (globais) do sistema, que nada mais é que o somatório de todas as cargas. Este modelo de previsão fornece informações de extrema importância para o sistema elétrico de potência, pois contribui para a tomada de decisões sobre alocação de recursos, planejamento de expansão da capacidade de geração e na minimização de perdas, entre outros (AMORIM, 2019).

Para uma melhor contribuição para a previsão de cargas, faz-se necessário conhecer os múltiplos pontos do sistema, pois nelas existem vários pontos de interligação entre linhas de distribuição, subestações, transformadores e consumidores, denominados de barramentos (multinodal). Como cada ponto do sistema atende uma clientela, é possível esboçar um histórico de demanda de carga e estudá-las. O estudo da carga multinodal é importante para que se possa garantir uma operação segura, confiável e sem interrupções.

No entanto, quando se trata de previsão de carga multinodal, estamos trabalhando com a carga individual (local), um elemento do sistema, que nada mais é que a carga em um barramento ou nó do sistema.

2.1 Variáveis que Influenciam o Comportamento da Carga

O sistema elétrico de potência atende diferentes tipos de consumidores que podem ser divididos em (LOPES, 2005):

- Residencial;
- Comercial;
- Industrial.

Cada consumidor, por sua vez, demanda diferentes cargas elétricas. Nas residências, por exemplo, seu comportamento é composto basicamente pelos aparelhos que a consomem, tais como: condicionadores de ar, chuveiro elétrico, refrigerador, lâmpadas, etc. Como cada residência tem hábitos e regras diferentes, isso torna difícil de determinar o desempenho da demanda de carga (ABREU *et al.*, 2020).

No comércio, em sua maioria, é determinado o tempo de uso de seus equipamentos elétricos, uma vez que seguem um padrão baseado no horário da jornada de trabalho. Basicamente, os equipamentos são compostos por ventiladores, condicionadores de ar, lâmpadas, geladeiras, entre outros (AMORIM, 2019).

Já os consumidores industriais são os que mais consomem energia do sistema, pois a demanda é previsível, visto que já têm um histórico de produção, mas podem ocorrer imprevistos, tais como a manutenção de maquinários e greves de funcionários, acarretando na interferência do sistema (AMORIM, 2019).

Além dessas variáveis existentes, temos outros fatores exógenos (GROSS; GALIANA, 1987) que agem de forma significativa para realizar a previsão de demanda de carga com precisão, os quais são:

- **Fatores Socioeconômicos:** são eventos relacionados à taxa de emprego, padrão residencial, índices de renda média, distribuição da população por faixas salariais, entre outros (MURTO, 1998);
- **Fatores Demográficos:** são eventos que ocorrem a longo prazo, tais como índices de densidade demográfica (hab/km²) e crescimento industrial (MURTO, 1998);
- **Fatores Temporais:** são eventos que podem ser cíclicos, acontecendo em certos períodos, tais como baixa demanda de energia elétrica durante os sábados e domingos e uma

alta demanda durante a semana. Podem ser sazonais, acontecendo em uma certa temporada, ou seja, mudanças de estação do ano. E os dias atípicos, tais como feriados, entre outros (O'DONOVAN, 1983; MURTO, 1998);

- **Fatores Climáticos:** são eventos relacionados à temperatura, chuva, neve, tempestades, níveis de luminosidade, velocidade do ar, umidade relativa do ar, etc. Estes fatores têm sido objeto de estudos de algumas pesquisas (MURTO, 1998);

- **Fatores Aleatórios:** eventos que não são passíveis de explicação como os anteriores. Esses fatores ocorrem de forma esporádica, tais como: eventos esportivos, programa de televisão, paralisação em indústrias e greves (MURTO, 1998). Essas interrupções refletem na previsão de demanda de energia, ocasionadas pelo fato de que as residências apresentam menor interferência em relação às interrupções industriais.

2.2 Classificação da Previsão de Carga

A previsão de cargas elétricas pode ser classificada de acordo com o seu horizonte de tempo, podendo ser modelada de acordo com a necessidade exigida em segundos, minutos, horas, dias, meses, anos ou décadas.

Existem quatro classificações para a previsão de cargas elétricas, são elas: (ALKANDARI; SOLIMAN; EL-HAWARY, 2004; METAXIOTIS *et al.*, 2003; MURTO, 1998; SWARUP; SATISH, 2002; YALCINOZ; EMINOGLU, 2004):

- **Previsão de Carga a Longo Prazo:** abrange um período de longa duração, anos ou até mesmo décadas. Este tipo de previsão é principalmente utilizado na operação de expansão do sistema;

- **Previsão de Carga a Médio Prazo:** abrange um período de poucas semanas ou até mesmo alguns anos. Este tipo de previsão é principalmente utilizado na alocação das máquinas geradoras com intuito de obter uma operação econômica;

- **Previsão de Carga a Curto Prazo:** abrange um período de meia hora a poucas horas ou até mesmo um dia a uma semana. Com este espaço de tempo esta previsão é principalmente utilizada para previsões operacionais, econômicas e de segurança diária do sistema elétrico de potência;

- **Previsão de Carga a Curtíssimo Prazo:** abrange um período de frações de segundos ou até mesmo podendo chegar a 15 minutos. Este tipo de previsão é muito utilizado para o planejamento de produção *on-line*.

2.3 Métodos para Previsão de Carga

Segundo Gross e Galiana (1987), existem vários métodos que foram desenvolvidos para concretizar a previsão de cargas elétricas, podendo ser classificados em:

- **Modelos Não-Dinâmicos:** 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 do tempo do dia, mas também de seus comportamentos mais recentes, ou seja, os valores da saída dependem dos valores das entradas.

Em relação aos métodos existentes, Murto (1998) define:

- **Métodos Estatísticos:** são metodologias baseadas em técnicas estatísticas nas quais há uma modelagem da carga, como por exemplo: regressão linear ou múltipla;
- **Sistemas Especialistas Baseados em Aprendizagem de Máquinas:** são baseados no conhecimento construído e, principalmente, com as regras que reproduz o conhecimento, sendo baseados na inteligência artificial e, consequentemente, capazes de reproduzir o raciocínio humano.

2.4 Estado da Arte

Na literatura existem poucas referências para a previsão de cargas por barramento, dentre elas destacam-se:

Rodrigues (2002) realizou a previsão de consumo de energia a curto prazo, fazendo um estudo de caso do ponto de vista do barramento, utilizando os dados de uma concessionária de Minas Gerais, foram utilizadas redes neurais do tipo MLP (*Multlayer Perceptron*). Os resultados finais de erros da previsão ficaram entre 3% à 5%.

Salgado (2004) desenvolveu um modelo de previsão de carga diária ativa, em base horária, por barramento e utilizando duas metodologias: a metodologia de previsão individual e a metodologia de previsão agregada. No trabalho foram utilizados dois algoritmos de agrupamentos: *Pruning Technique Kohonen Self-Organizing Feature Map-PSOM* e *Fuzzy C-means – FCM*. O modelo de previsão individual foi mais eficaz em grande parte do barramento, mesmo tendo o modelo de previsão agregada apresentado erros inferiores quando comparado ao modelo de previsão individual.

No trabalho de Altran (2010) é desenvolvida uma metodologia para prever cargas multinodais utilizando uma rede neural artificial. Esta rede do tipo *perceptron* multicamadas, cujo treinamento foi baseado no algoritmo retropropagação. Porém, foi realizada uma modificação na função de ativação da rede, em substituição à função usual, a função sigmoide. Assim, foram utilizadas as funções de base radial. Tal metodologia foi aplicada ao problema de previsão de cargas elétricas a curto-prazo global e multinodal baseado no conceito de fator de participação da carga global (24 horas à frente). O MAPE alcançado foi de 1,43% para previsão global e na previsão local de 2,93%.

Nose-Filho *et al.* (2011) elaborou um modelo predictor de carga multinodal de curto prazo, utilizando redes neurais de regressão generalizada (GRNN) e, além disso, projetou uma nova arquitetura de rede neural artificial, baseada na GRNN, propôs um procedimento para a redução do número de entradas da GRNN e um filtro para o pré-processamento do banco de dados de treinamento. Os MAPEs diários encontrados para as nove subestações analisadas variam de 2,18% a 7,75%.

Já Bordignon (2012) apresenta uma metodologia de previsão de cargas a curtíssimo prazo, considerando as influências das condições climáticas. Essa metodologia envolve a criação de um modelo probabilístico discreto (cadeia de Markov) a partir da classificação dos dados históricos em um Mapa Auto-Organizável (SOM). Os resultados adquiridos na maior parte dos testes ficaram com erro abaixo de 5%, sendo aceitável para previsões de carga de curtíssimo prazo.

Abreu *et al.* (2018) propôs um sistema preditivo usando a rede neural ARTMAP *Fuzzy*, o conceito do fator de participação e uma correção “prorata”, com o objetivo de reduzir o tempo de processamento das previsões de cargas locais. Os resultados obtidos para as previsões multinodais atenderam às exigências do sistema elétrico.

Amorim *et al.* (2020) desenvolveu um método preditivo multinodal para os sistemas de energia elétrica, utilizando uma rede neural ARTMAP *Fuzzy*. O artigo emprega um conceito novo de treinamento reverso para prever a demanda de carga global de vários nós de uma rede

elétrica 24 horas à frente. A metodologia proposta mostra que o novo algoritmo para o treinamento da rede neural é robusto e confiável, pois foi capaz de reduzir o MAPE de 3,04% para 0,61% e o tempo de processamento em aproximadamente 80 segundos.

Observa-se que há décadas tem sido estudada a previsão de cargas nos barramentos e todos os trabalhos citados acima ressaltam a importância da previsão das cargas para o sistema de energia elétrica.

No presente trabalho será abordada a questão da previsão de cargas multinodais utilizando a rede neural artificial ARTMAP *Fuzzy*, a fim de analisar e identificar o impacto das agregações das subestações e verificar se irá refletir no retorno das mesmas na carga individual de cada subestação, visando à melhoria da previsão de carga multinodal.

3 ANÁLISE DA AGREGAÇÃO DE CARGAS ELÉTRICAS DE SUBESTAÇÕES PARA MELHORIA NA PREVISÃO DE CARGA MULTINODAL UTILIZANDO A REDE NEURAL ARTMAP FUZZY

O objetivo desta dissertação é apresentar uma nova metodologia de previsão de carga multinodal (subestações), considerando vários pontos do sistema de energia elétrica. Portanto, será tratado o tema a respeito da previsão de carga elétrica em subestações utilizando técnicas baseadas em aprendizagem de máquinas alicerçadas na previsão realizada em blocos (subestações agregadas).

A previsão realizada de forma agregada tende a apresentar menores erros, se comparada à previsão desagregada. Desta forma, propõe-se estabelecer uma forma de utilizar a vantagem da previsão de demanda agregada, ou seja, uma vez realizada a previsão de carga elétrica multinodal agregada (subestações agregadas), esta irá compor o conjunto de dados de entrada para o novo sistema de previsão local que terá como incumbência prever os valores de demanda das subestações que foram agregadas no sistema.

Neste sentido, para desenvolver esta metodologia é necessário realizar os seguintes passos:

1. Prever a carga elétrica global do sistema (PCG);
2. Prever as cargas elétricas em vários nós do sistema (carga multinodal), (PCM);
3. Agregar alguns nós do sistema e verificar como o comportamento das cargas elétricas agregadas (blocos) influenciam o sistema;
4. Analisar as cargas agregadas e, a partir delas, prever as cargas elétricas nodais (subestações) que foram agregadas.

As previsões de cargas elétricas globais, nodais (subestações) e agregadas são realizadas pela rede neural ARTMAP *Fuzzy*.

3.1 Base de Dados

Os dados históricos foram disponibilizados pelo Electricity Commission da Nova Zelândia, e coletados no Centralized Dataset (CDS) (2010). Essa base de dados contém os valores de potência ativa, medidos de meia em meia hora em cada uma das subestações e são

referentes ao dia do mês, mês, ano, dia da semana, feriado, horário de verão e valor da amostra de carga. Como os valores são medidos de meia em meia hora, as amostras para um dia (24 horas) correspondem a 48 amostras.

Esses dados foram utilizados em alguns trabalhos do grupo de pesquisa do laboratório SINTEL (Sistemas inteligentes) da Unesp - Câmpus Ilha Solteira, como: Nose-Filho (NOSE-FILHO, 2010), Altran (ALTRAN, 2010) e Antunes (ANTUNES, 2013).

As nove subestações a serem trabalhadas pertencem à região de Waikato, localizada ao norte da ilha de Nova Zelândia, sendo elas: Kopu, Waikino, Waihou, Hamilton 11, Hamilton 33, Cambridge, Te Awamutu, Hinuera e Kinleith.

A figura 1 mostra o mapa da rede de transmissão de energia no norte da Ilha da Nova Zelândia, contendo a representação de suas várias subestações, linhas de distribuições e estações de energia.


Figura 1 - Mapa da rede de transmissão de energia no norte da Ilha de Nova Zelândia.



Fonte: Transpower Transmission Network (2020).

Na figura 2 é apresentado o diagrama elétrico, no qual pode-se observar a linha de transmissão fornecida para cada subestação, bem como a ordem das subestações, transformadores e estação de energia.

Figura 2 - Diagrama Elétrico.



Fonte: Nose Filho (2010).

A tabela 1 apresenta as especificações dos transformadores que compõem cada uma das nove subestações:

Tabela 1 - Especificações dos transformadores de cada subestação.

Subestação	Tensão (kV)	Potência (MVA)
#01 Kopu	2 x 110/66	2 x 45
#02 Waikino	2 x 110/33	2 x 30
#03 Waihou	3 x 110/33	3 x 20
#04 Hamilton 11	2 x 110/11	2 x 40
#05 Hamilton 33	2 x 220/33	2 x 100
#06 Cambrigde	2 x 110/11	2 x 38
#07 Te Awamutu	2 x 110/11	2 x 40
#08 Hinuera	2 x 110/33	1 x 30 + 1 x 50
#09 Kinleith	1 x 110/33	1 x 30
Total	2 x 220/33 + 2 x 110/66 + 8 x 110/33 + 6 x 110/11	756

Fonte: Nose-Filho (2010).

Para a validação dos testes foram analisados os dados do dia 08/12/2008 até o dia 07/01/2009, tornando-se possível prever a demanda de cargas para o dia 08/01/2009.

3.2 Procedimento de Previsão Multinodal utilizando Cargas Agregadas

A agregação dos nós (subestações) na previsão de cargas elétricas multinodais é importante, pois tem como fundamento reduzir o tempo de processamento das cargas elétricas,

uma vez que quando as cargas estão agregadas, o número de informações que se tem para fazer as previsões são menores, ou seja, é menor o número de fatores influenciando sua carga quando comparado com um sistema total de energia elétrica.

A agregação refere-se às possíveis combinações dos nós (subestações), agrupando-os de várias maneiras, seja pela proximidade das subestações, ou até mesmo pela região em que se encontram.

Pode-se encontrar na literatura trabalhos que utilizaram esta técnica e que confirmam a vantagem do uso da previsão agregada em relação à redução do tempo de processamento das cargas e a redução do erro obtido na previsão agregada (ALTRAN, 2010).

Uma desvantagem referente à previsão de carga agregada está no fato de esta não ser capaz de retornar ao sistema a previsão individual de cada subestação agregada. Desta forma, torna-se vantajoso utilizar a previsão de carga agregada para reduzir de certa forma o tamanho e complexidade do sistema, e partindo dos nós agregados (blocos), criar uma estratégia de previsão agregada dos nós utilizando a rede ARTMAP *Fuzzy*.

Cada bloco (subestações agregadas) se tornaria um conjunto de cargas globais agregadas para as subestações utilizadas e não para o sistema global, que seria utilizada como dados de entrada da rede neural. Portanto, espera-se que a redução no erro da previsão de carga agregada reduza também o erro na previsão local (subestações que foram agregadas).

A metodologia é baseada em uma sequência de passos a serem desenvolvidos, sendo que um passo depende do passo anterior. São eles:

Passo 1: Realizar a previsão de carga elétrica global do sistema analisado;

Passo 2: Realizar a previsão de carga multinodal visando a previsão de cargas elétricas das subestações utilizando a definição de fator de participação de carga global (referência);

Passo 3: A partir das previsões realizadas no passo 2, identificar as subestações que podem ser agregadas para a melhoria do sistema;

Passo 4: Para as cargas agregadas no passo 3, criar um modelo neural para prever as cargas multinodais que foram agregadas.


Para melhor entendimento da metodologia proposta, serão descritos seguidamente o desenvolvimento dos passos 1 a 4.

3.2.1 Previsão de Carga Global (PCG)

A Carga Global (CG) é prevista pela rede neural ARTMAP *Fuzzy* e é composta por dois módulos: ART_a (entrada) e ART_b (saída).

No módulo ART_a as variáveis de entrada são constituídas por dados exógenos, valores de carga global em três tempos anteriores, $h-1$, $h-2$ e $h-3$, conforme a figura 3.

Figura 3 - Entrada da RNA para PCG.




Fonte: Abreu *et al.* (2019).

Os dados exógenos são compostos por: dia da semana, horário de verão, feriado/dia atípico e tempo do dia, todos representados de forma binária. O tempo do dia refere-se ao momento do dia (segundo, minuto ou hora) no qual a carga está sendo relacionada. O tempo do dia utilizado foi meia hora, portanto, para prever a carga elétrica de um dia (24 horas) são necessários 48 dados de cargas elétricas de meia em meia hora.

A representação das cargas globais contempla um movimento de janela (ALTRAN, 1999), que é realizado com o objetivo de a rede identificar o comportamento do perfil da carga.

A saída da rede neural ARTMAP *Fuzzy* é dada pelo valor de carga elétrica global subsequente, ou seja, no instante h , conforme mostra a figura 4.

Figura 4 - Saída da RNA para PCG.



Fonte: Abreu *et al.* (2019).

A tabela 2 apresenta a forma em que os dados exógenos foram utilizados no conjunto de entrada da rede neural ARTMAP *Fuzzy*.

Tabela 2 - Dados exógenos utilizados nos dados de entrada da rede neural ARTMAP *Fuzzy*.

Dados Exógenos	Informação
Dia da Semana (3bits)	[001] - Segunda
	[010] - Terça
	[011] - Quarta
	[100] - Quinta
	[101] - Sexta
	[110] - Sábado
	[111] - Domingo
Tempo (6 bits)	[000001] – 1
	⋮ ⋮
	[110000] – 48
Feriado (1 bit)	1 – feriado
	0 – não é feriado
Horário de verão (1 bit)	1 – horário de verão
	0 – não está no horário de verão

Fonte: Autoria Própria.

Portanto, o sistema de dados de entrada é composto por um conjunto que contém 11 bits relacionados aos dados exógenos, acrescidos de mais 3 valores de cargas e o conjunto de saída apenas 1 valor de carga.

3.2.2 Previsão de Carga Multinodal (PCM)

A Previsão Multinodal é realizada de forma semelhante à Previsão Global, ou seja, para cada janela o ajuste de peso deve ser realizado, como no PCG, nos demais módulos que compõem a PCM. Neste modelo, os módulos locais em todos os barramentos do sistema elétrico são paralelos, isto é, podem ser processados independentemente.

A estimativa de carga, para cada ponto de interesse da rede, é dada pelo conceito de Fator de Participação da Carga Global (FPCG), determinado pela equação (1) (NOSE FILHO *et al.*, 2011; ALTRAN, 1999):

$$FPCG_j = \frac{CM_j}{CG} \quad (1)$$


Sendo:

CM_j : Carga Multinodal referente ao j -ésimo ponto de interesse (transformadores, alimentadores, subestações, etc.);

CG : Soma das cargas de todas as subestações.

Assim, as entradas da RNA ARTMAP Fuzzy (ART_a) para cada subestação j é composta por uma entrada de CG, no instante atual (instante h), e entradas de FPCG, constituídas por valores em instantes passados ($h - 1$; $h - 2$, $h - 3$), conforme ilustra a figura 5.

Figura 5 - Entrada da RNA para PCM.




Fonte: Abreu *et al.* (2019).

A saída da rede neural ARTMAP Fuzzy para a PCM é dada pelo valor do fator de participação no instante h e essa estrutura pode ser visualizada na figura 6.

Observa-se, por meio das figuras 5 e 6, que o sistema de dados de entrada é composto por um conjunto que contém 1 valor de carga e 3 valores de fator de participação e o conjunto de saída apenas 1 fator de participação global previsto para j -ésima subestação.

Figura 6 - Saída da RNA para PCM.



Fonte: Abreu *et al.* (2019).

Obtidos os valores dos Fatores de Participação Globais para cada subestação j , é calculada e realizada a PCM, de acordo com a equação (2):

$$PCM_j = FPCG_j(h) \times PCG(h) \quad (2)$$

3.2.3 Previsão de Cargas Multinodais Agregadas (PCMA)

Para realizar a agregação das subestações, foi utilizada a técnica de agrupamento das cargas, processo definido como o somatório das cargas dos barramentos agregados em cada grupo, intervalo, dia e instante de tempo. A equação (3) é utilizada para obter a demanda de carga agregada no grupo g , no dia d e no instante h :

$$Da(g, d, h) = \sum_{i=1}^n C(i, d, h) \quad (3)$$

No qual:

$Da(g, d, h)$: Demanda de carga agregada no grupo g no dia d e instante h ;

n : Número de barramentos pertencentes ao grupo g ;

$C(i, d, h)$: Carga dos i barramentos pertencentes ao grupo g no dia d e instante h .

A previsão da carga multinodal agregada (PCMA) é efetuada apenas para o grupo agregado, $Da(g, d, h)$. As cargas elétricas dos nós (subestações) que não foram agregados já foram previstos pelo sistema previsor de carga multinodal e, portanto, não são levados em consideração nesta etapa.

Para realizar o cálculo da PCMA de cada agrupamento de interesse da rede, é utilizado o conceito de Fator de Participação da Carga Global Agregada (FPCGA), determinado pela equação (4):

$$FPCGA = \frac{Da(g,d,h)}{CG} \quad (4)$$

Sendo:


FPCGA : Fator de participação da carga global agregada;

Da(g,d,h) : Demanda de carga agregada referente ao ponto de interesse (transformadores, alimentadores, subestações, etc.);

CG : Soma de todas as subestações das Cargas Multinodais.

Do mesmo modo, as entradas da RNA ARTMAP *Fuzzy* (ART_a) para cada grupo de subestações agregadas é composta pela carga global, no instante atual (h), fator de participação de carga global agregada, *FPCGA*, nos instantes $(h - 1; h - 2, h - 3)$, conforme ilustra a figura 7.

Figura 7 - Entrada da RNA para PCMA.



Fonte: Autoria Própria.

A saída do módulo ART_b da rede ARTMAP *Fuzzy* é representada pelo *FPCGA* no instante h , e pode ser visualizada na figura 8.

Figura 8 - Saída da RNA para PCMA.



Fonte: Autoria Própria.

Obtidos os valores dos fatores de participação globais agregada para j -ésimo grupo agregado, é calculada e realizada a PCMA, de acordo com a equação (5):

$$PCMA_j = FPCGA_j(h) \times PCG(h) \quad (5)$$

3.2.4 Previsão Multinodal realizada através das Previsões Agregadas (PMPA)

As cargas multinodais são cargas desagregadas e, portanto, as previsões tornam-se menos precisas. No intuito de melhorar as previsões, é utilizada a estratégia de agrupamento das subestações mais sensíveis, visando à melhoria nas previsões. Porém, uma vez agrupado um conjunto de subestações, perde-se a informação referente às subestações que foram agregadas.

Portanto, a ideia é utilizar um sistema previsor de carga multinodal com cargas agregadas (PMPA) para prever apenas as cargas elétricas das subestações usadas no conjunto agregado dado pela equação (3).

Para realizar o retorno das cargas agregadas para cada subestação, foram utilizadas as cargas agregadas como a Nova Carga Global (NCG), equação (6), e aplicado o conceito de fator de participação da nova carga global. O fator de participação referente a cada subestação agregada é dado pela equação (7):

$$NCG = Da(g, d, h) \quad (6)$$


$$FPNCG = \frac{Sub_i(i, d, h)}{NCG} \quad (7)$$

Sendo que:

- NCG : Nova carga global;
 $Da(g,d,h)$: Demanda de carga agregada no grupo g , no dia d e instante h ;
 $FPNCG$: Fator de participação da nova carga global;
 $Sub_i(i, d, h)$: Subestação i , no dia d e instante h .

O sistema PMPA tem a finalidade de realizar a previsão das cargas das subestações do conjunto $Da(g,d,h)$. O conjunto de entradas utilizada na rede ARTMAP Fuzzy para i -ésima subestação que compõem o conjunto $Da(g,d,h)$ é composta pelo valor da nova carga global no instante de tempo h , e os fatores de participação da i -ésima subestação de $Da(g,d,h)$ FPNCG, nos instantes de tempos, $h-1$, $h-2$ e $h-3$, conforme mostra a figura 9.


Figura 9 - Entrada da RNA para PMPA.



Fonte: Autoria Própria.

A saída da rede neural ARTMAP Fuzzy para o sistema PMPA é dada pelo valor do fator de participação de carga agregada no instante h e pode ser visualizada na figura 10.

Figura 10 - Saída da RNA para PMPA.



Fonte: Autoria Própria.

Uma vez obtidos os valores dos fatores de participação das novas cargas globais para j -ésima subestação, é calculada e realizada a PCMA, de acordo com a equação (8):

$$PMPA_j = FPNCG_j(h) \times PCM_j(h) \quad (8)$$

4 RESULTADOS

O conjunto de dados utilizado nesta pesquisa foi cedido pelo setor elétrico da Nova Zelândia. O conjunto de dados usados na fase de treinamento são referentes a um período de um mês de consumo (08 de Dezembro de 2008 a 7 de Janeiro de 2009) o que totaliza um conjunto com 1448 pontos (31 dias x 48 medições por dia), e, para realizar a previsão, foi utilizado o dia 08/01/2009, ou seja, 24 horas (um dia) à frente, sendo medidos em intervalos de 30 em 30 minutos, totalizando 48 pontos.

Todos os testes foram simulados e realizados no Software MATLAB R2016b. Para prever as cargas globais e cargas locais em todos os casos de estudo foi utilizada a rede neural ARTMAP *Fuzzy*.

Os parâmetros que estão relacionados tanto para o treinamento quanto para o diagnóstico foram obtidos por meio de tentativas e erros e, portanto, os parâmetros foram selecionados baseados na realização de vários testes. Assim, não foi utilizada nenhuma técnica de otimização para encontrar os parâmetros a serem utilizados.

4.1 Parâmetro de Análise dos Resultados

Para verificar e analisar a precisão da metodologia proposta, foi utilizado o Erro Percentual Médio Absoluto - MAPE (SRINIVASAN *et al.*, 1998), como um critério de avaliação, que nada mais é que a soma dos percentuais absolutos dos erros divididos pelo número de observações. Assim, o MAPE identifica o percentual médio que a previsão desviou do valor desejado e pode ser obtido pela equação (9):

$$MAPE = \frac{1}{NA} \sum_{h=1}^{NA} \left| \frac{C_{real}(h) - C_{prevista}(h)}{C_{real}(h)} \right| \times 100 \quad (9)$$

Sendo:

- $MAPE$: Erro percentual médio absoluto;
- NA : número de amostras da série temporal;
- C_{real} : valor da carga real no instante h ;
- $C_{prevista}$: valor da carga prevista no instante h .

4.2 Resultado Obtido para Previsão Global

A carga global é obtida considerando todo o sistema elétrico e o resultado obtido refere-se à previsão da carga global do dia 08/01/2009, ou seja, 48 valores de carga global previstos de 30 em 30 minutos. O MAPE obtido ao realizar a previsão global foi de 2,9139%, e os parâmetros utilizados pela rede neural ARTMAP são mostrados na tabela 3.


Tabela 3 - Parâmetros da rede neural ARTMAP *Fuzzy* para previsão global.

ρ_{ab}	ρ_a	ρ_β	β	α	ε
1,000	0,990	0,992	1,000	0,700	0,005

Fonte: Autoria Própria (2020).

Na figura 11, está ilustrada a curva da previsão da carga global real e a carga global prevista para o dia 08/01/2009. Observa-se que a carga elétrica prevista pela rede neural ARTMAP *Fuzzy* mantém o comportamento da carga real.

Figura 11 - Curvas de carga elétrica global real e prevista pela rede neural ARTMAP *Fuzzy*.



Fonte: Autoria Própria.

4.3 Resultados Obtidos para Previsão Multinodal

Para realizar a previsão local de cada subestação, foram utilizados os dados previstos pela carga global, bem como os dados de fator de participação respectivos de cada subestação. Os valores dos MAPEs encontrados podem ser conferidos na tabela 4. Na última linha da tabela 4 está o valor do erro obtido pela soma das cargas previstas por cada uma das subestações, a qual denotaremos a previsão da carga global obtida pela soma das subestações (PCGSS). A curva da PCGSS está ilustrada na figura 14.

Tabela 4 - Valores do erro percentual médio absoluto das subestações obtidas através da rede ARTMAP *Fuzzy*.

Número da Subestação	Subestação	MAPE (%)
#01	Kopu	5,9102
#02	Waikino	12,2909
#03	Waihou	3,5178
#04	Hamilton 11	6,0190
#05	Hamilton 33	4,2064
#06	Cambridge	4,7037
#07	Te Awamutu	4,9943
#08	Hinuera	6,4905
#09	Kinleith	10,8801
#SOMA	PCGSS	1,3336

Fonte: Autoria Própria.

Os parâmetros utilizados em cada subestação estão listados na tabela 5:


Tabela 5 - Parâmetros da rede neural ARTMAP *Fuzzy* para previsão das subestações.

Parâmetros	Subestações								
	#01	#02	#03	#04	#05	#06	#07	#08	#09
β	1	1	1	1	1	1	1	1	1
ρ_{ab}	1	1	1	1	1	1	1	1	1
ρ_a	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9	0,9
ρ_b	0,995	0,999	0,999	0,99992	0,999	0,999	0,999	0,995	0,9992
α	0,7	0,7	0,7	0,7	0,7	0,7	0,7	0,7	0,6
Incremento (ϵ)	0,0005	0,005	0,005	0,0005	0,0005	0,0005	0,0005	0,0005	0,5

Fonte: Autoria Própria.


Cada subestação tem uma influência significativa para o sistema, mesmo sendo umas maiores que as outras, porém atendem à demanda de carga para os consumidores. Os gráficos para cada uma das subestações citadas na tabela 4 estão ilustrados nas figuras 12 e 13.

Figura 12 - Curva de Carga elétrica local real e prevista, dada pela a rede neural ARTMAP Fuzzy, das subestações de Kopu, Waikino, Waihou, Hamilton 11, Hamilton 33 e Cambridge.



Fonte: Autoria Própria.

Figura 13 - Curva de carga elétrica local real e prevista, dada pela rede neural ARTMAP Fuzzy, das subestações de Te Awamutu, Hinuera e Kinleith.




Fonte: Autoria Própria.

Pode-se notar, por meio da tabela 4, que os valores relacionados ao MAPE para algumas subestações são superiores a 5%. Na literatura, um erro superior a este valor não é favorável para fornecer energia de forma confiável (SRINIVASAN *et al.*, 1998).

A figura 14 ilustra as curvas de previsão global real e a obtida como resultado da soma das subestações (PCGSS) e o erro de previsão obtido para esta análise foi de 1,3336%.

Figura 14 - Curvas de carga elétrica global real e prevista pela rede neural ARTMAP *Fuzzy* através da soma das previsões de cargas multinodais.



Fonte: Autoria Própria.

4.4 Resultados Obtidos para Previsão Agregada

À medida que se observou a previsão das cargas, definiu-se trabalhar com blocos agregados, pois estas cargas, quando agregadas, possuem uma menor quantidade de fatores influenciando-as e, ainda, um erro menor do que quando comparado com as cargas em suas subestações sozinhas.

À princípio as agregações foram realizadas utilizando o diagrama elétrico do sistema da Figura 2. Porém, observou-se que as melhores agregações eram obtidas analisando-se o equilíbrio das previsões das cargas individuais do sistema, ou seja, agrupando subestações que apresentavam, nas previsões locais realizadas pela rede neural ARTMAP *Fuzzy*, menores e maiores valores de MAPE. Foram realizados vários testes utilizando duas, três e até mesmo quatro subestações agregadas, a fim de verificar o melhor desempenho dos resultados.

- **Análise 1: Agregação das subestações {Hamilton 11, Hamilton 33, Kinleith}**

Na tabela 6 serão mostrados os valores de MAPEs da previsão local, das cargas agregadas, e da previsão para a carga global (PCGSS) realizada após a agregação.

Como observado na tabela 6, existe apenas um bloco agregado composto pelas subestações de Hamilton 11, Hamilton 33 e Kinleith. O MAPE obtido na agregação foi de 9,9212%, sendo superior ao de duas subestações em estudo. O resultado obtido para a PCGSS também obteve uma perda de desempenho, quando as subestações foram agregadas.

Tabela 6 - Valores do erro percentual médio absoluto das subestações individuais e agregadas obtidas através da rede ARTMAP *Fuzzy* para análise 1.

Subestação	MAPE (%) Locais	MAPE (%) com agregação
Kopu	5,9102	5,9102
Waikino	12,2909	12,2909
Waihou	3,5178	3,5178
Hamilton 11	6,0190	9,9212
Hamilton 33	4,2064	
Kinleith	10,8801	
Cambridge	4,7037	4,7037
Te Awamutu	4,9943	4,9943
Hinuera	6,4905	6,4905
PCGSS	1,3336	5,6186


Fonte: Autoria Própria.

Observando o diagrama elétrico disposto na figura 2, temos que, entre as subestações de Hamilton 11 e Hamilton 33, há um transformador, separando a Hamilton 33 das demais subestações, fazendo com que a agregação de qualquer subestação com a Hamilton 33, em sua maioria, não gere bons resultados.

Na figura 15, é possível observar a previsão da carga agregada referente à análise 1 e o valor de carga agregada real das subestações Hamilton 11, Hamilton 33 e Kinleith.

Fonte: Autoria Própria.

Figura 15 - Previsão da carga agregada real e carga agregada prevista pela rede ARTMAP *Fuzzy* para análise 1.



- **Análise 2: Agregação das subestações {Waikino, Waihou}, e {Hamilton 11, Kopu, Hinuera, Kinleith}**

Na tabela 7 estão os resultados obtidos para dois blocos agregados: o primeiro é composto pelas subestações Waikino e Waihou, já o segundo bloco é formado pelas subestações, Hamilton 11, Kopu, Hinuera e Kinleith.

Tabela 7 - Valores do erro percentual médio absoluto das subestações individuais e agregadas obtidas através da rede ARTMAP *Fuzzy* para análise 2.

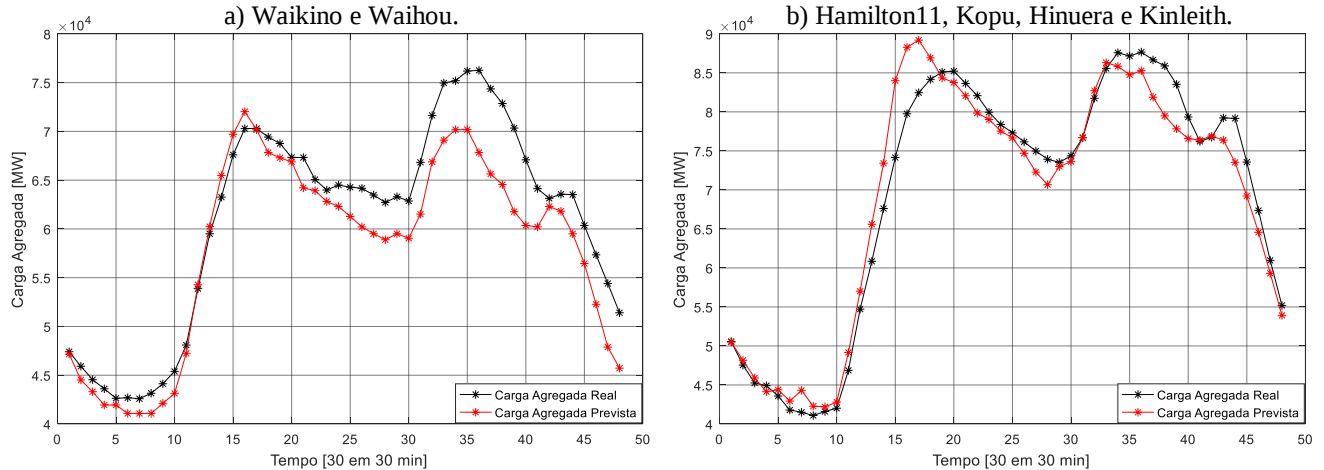
Subestação	MAPE (%) Locais	MAPE (%) com agregação
Waikino	12,2909	5,1374
Waihou	3,5178	
Hamilton 11	6,0190	3,4179
Kopu	5,9102	
Hinuera	6,4905	
Kinleith	10,8801	
Hamilton 33	4,2064	4,2064
Cambridge	4,7037	4,7037
Te Awamutu	4,9943	4,9943
PCGSS	1,3336	1,1277

Fonte: Autoria Própria.

O primeiro bloco teve agregação satisfatória apenas para a subestação de Waikino, indicado pela diminuição no MAPE, porém, para a subestação de Waihou, o erro da carga agregada ficou superior, tornando essa agregação desinteressante. No segundo bloco, observa-se que a agregação realizada obteve um resultado significativo, visto que o MAPE apresentou significativa redução em relação às quatro subestações agregadas.

A figura 16 apresenta a previsão da carga agregada referente à análise 2 e o valor de carga agregada real, considerando dois blocos de agregações realizadas: a) Waikino e Waihou e b) Hamilton 11, Kopu, Hinuera e Kinleith.

Figura 16 - Previsão da carga agregada real e carga agregada prevista pela rede ARTMAP Fuzzy para análise 2 para os blocos agregados: a) Waikino e Waihou e b) Hamilton 11, Kopu, Hinuera e Kinleith.



Fonte: Autoria Própria.

- Análise 3: Agregação das subestações {Kopu, Waikino, Hamilton 11}, {Cambridge, Hinuera}, e {Te Awamutu e Kinleith}**

Na tabela 8 foram três blocos agregados, no primeiro composto pelas subestações, Kopu, Waikino e Hamilton 11, o segundo formado pelas subestações, Cambridge e Hinuera, e o terceiro composto pelas subestações, Te Awamutu e Kinleith.


Tabela 8 - Valores do erro percentual médio absoluto das subestações individuais e agregadas obtidos através da rede ARTMAP Fuzzy para análise 3.

Subestação	MAPE (%) Locais	MAPE (%) com agregação
Kopu	5,9102	5,7778
Waikino	12,2909	
Hamilton 11	6,0190	
Waihou	3,5178	3,5178
Hamilton 33	4,2064	4,2064
Cambridge	4,7037	8,5942
Hinuera	6,4905	
Te Awamutu	4,9943	3,6466
Kinleith	10,8801	
PCGSS	1,3336	1,1405

Fonte: Autoria Própria.

Um fato interessante a se observar é que no segundo bloco agregado o valor do MAPE fica maior do que quando as cargas estavam individuais, porém quando analisada a PCGSS, há uma diminuição do erro. Já nos demais blocos, as agregações são boas, pois não apresentaram resultados do MAPE superiores aos valores das cargas previstas iniciais.

Figura 17 - Previsão da carga agregada real e carga agregada prevista pela rede ARTMAP Fuzzy para análise 3 para os blocos agregados: a) Kopu, Waikino e Hamilton 11, b) Cambridge e Hinuera e c) Te Awamutu e Kinleith.



Fonte: Autoria Própria.

Na figura 17 tem-se o valor da previsão de carga agregada referente à análise 3 e o valor de carga agregada real, considerando três blocos de agregações realizadas: a) Kopu, Waikino e Hamilton 11, b) Cambridge e Hinuera e c) Te Awamutu e Kinleith.

- **Análise 4: Agregação das subestações {Kopu, Waikino, Hinuera} e {Hamilton 11, Cambridge, Kinleith}**

Na tabela 9, tem-se dois blocos agregados, o primeiro composto pelas subestações, Kopu, Waikino e Hinuera, e o segundo formado pelas subestações, Hamilton 11, Cambridge e Kinleith.

Tabela 9 - Valores do erro percentual médio absoluto das subestações individuais e agregadas obtidas através da rede ARTMAP *Fuzzy* para análise 4.


Subestação	MAPE (%) Locais	MAPE (%) com agregação
Kopu	5,9102	6,0417
Waikino	12,2909	
Hinuera	6,4905	
Waihou	3,5178	3,5178
Hamilton 33	4,2064	4,2064
Hamilton 11	6,0190	4,3982
Cambridge	4,7037	
Kinleith	10,8801	
Te Awamutu	4,9943	4,9943
PCGSS	1,3336	0,9335

Fonte: Autoria Própria.

No primeiro bloco observa-se que o valor do MAPE para as cargas agregadas é superior na subestação de Kopu, e inferior para as outras duas subestações individuais utilizadas para agregar. Também pode ser analisado que a agregação para o segundo bloco é interessante, pois quando comparado com suas cargas individuais, o seu erro reduz de forma positiva nas três subestações.

A figura 18 mostra o resultado obtido para previsão da carga agregada referente à análise 4 e o valor de carga agregada real considerando dois blocos de agregações realizadas: a) Kopu, Waikino e Hinuera e b) Hamilton 11, Cambridge e Kinleith.

Figura 18 - Previsão da carga agregada real e carga agregada prevista pela rede ARTMAP Fuzzy para análise 4 para os blocos agregados: a) Kopu, Waikino e Hinuera e b) Hamilton 11, Cambridge e Kinleith.



Fonte: Autoria Própria.

- Análise 5: Agregação das subestações {Hamilton 11, Cambridge, Kinleith} e {Waikino, Hinuera, Te Awamutu}**

Na tabela 10 foram realizados dois blocos de agregamento, o primeiro com as subestações, Hamilton 11, Cambridge e Kinleith, e o segundo com as subestações, Waikino, Te Awamutu e Hamilton 33.

Tabela 10 - Valores do erro percentual médio absoluto das subestações individuais e agregadas obtidas através da rede ARTMAP Fuzzy para análise 5.


Nome	MAPE (%) Locais	MAPE (%) com agregação
Kopu	5,9102	5,9102
Waihou	3,5178	3,5178
Hamilton 11	6,0190	4,3982
Cambridge	4,7037	
Kinleith	10,8801	
Hinuera	6,4905	6,4905
Waikino	12,2909	3,0596
Te Awamutu	4,9943	
Hamilton 33	4,2064	
PCGSS	1,3336	2,5740

Fonte: Autoria Própria.

É possível observar que, para ambos os blocos agregados, seus resultados são inferiores quando comparados com suas cargas individuais.

Na figura 19 tem-se a ilustração do resultado obtido para previsão da carga agregada referente à análise 5 e o valor de carga agregada real considerando dois blocos de agregações realizadas: a) Hamilton 11, Cambridge e Kinleith e b) Waikino, Te Awamutu e Hamilton 33.

Figura 19 - Previsão da carga agregada real e carga agregada prevista pela rede ARTMAP Fuzzy para análise 5 para os blocos agregados: a) Hamilton11, Cambridge e Kinleith e b) Waikino, Te Awamutu e Hamilton 33.



Fonte: Autoria Própria.

- **Análise 6: Agregação das subestações {Hamilton 11, Hamilton 33, Cambridge} e {Waikino, Hinuera, Kinleith}**

Na tabela 11 há dois blocos agregados, o primeiro composto pelas subestações, Hamilton 11, Hamilton 33 e Cambridge, e o segundo composto pelas subestações, Waikino, Hinuera e Kinleith.

É possível observar que o valor do MAPE, para as cargas agregadas do primeiro bloco, é mais preciso para a subestação Hamilton 33 e menos preciso para as subestações Hamilton 11 e Cambridge. Na agregação do segundo bloco, é possível observar que o valor dos MAPEs para as cargas agregadas ficou muito baixo, visto que suas cargas individuais possuem as duas subestações com maiores valores de erros do sistema, ou seja, as mais difíceis de realizar a previsão, mostrando que há um equilíbrio para as cargas.


Tabela 11 - Valores do erro percentual médio absoluto das subestações individuais e agregadas obtidas através da rede ARTMAP *Fuzzy* para análise 6.

Nome	MAPE (%) Locais	MAPE (%) com agregação
Kopu	5,9102	5,9102
Waihou	3,5178	3,5178
Hamilton 11	6,0190	4,7561
Hamilton 33	4,2064	
Cambridge	4,7037	
Te Awamutu	4,9943	4,9943
Waikino	12,2909	3,7562
Hinuera	6,4905	
Kinleith	10,8801	
PCGSS	1,3336	1,4801

Fonte: Autoria Própria.

A figura 20 ilustra o resultado obtido para a previsão da carga agregada referente à análise 6 e o valor de carga agregada real considerando dois blocos de agregações realizadas: a) Hamilton 11, Hamilton 33 e Cambridge e b) Waikino, Hinuera e Kinleith.

Figura 20 - Previsão da carga agregada real e carga agregada prevista pela rede ARTMAP *Fuzzy* para análise 6 para os blocos agregados: a) Hamilton 11, Hamilton 33 e Cambridge e b) Waikino, Hinuera e Kinleith.



Fonte: Autoria Própria.

- **Análise 7: Agregação das subestações {Hamilton 11, Cambridge, Kinleith} e {Waikino, Hinuera, Te Awamutu}**

Na tabela 12, foram realizados dois blocos, o primeiro composto pelas subestações Hamilton 11, Cambridge e Kinleith, o segundo composto pelas subestações, Waikino, Hinuera e Te Awamutu. Nota-se que, com as agregações realizadas, os resultados foram inferiores em todos os casos, tornando-os interessantes a se investigar.


Tabela 12 - Valores do erro percentual médio absoluto das subestações individuais e agregadas obtidas através da rede ARTMAP *Fuzzy* para análise 7.

Subestação	MAPE (%) Locais	MAPE (%) com agregação
Kopu	5,9102	5,9102
Waihou	3,5178	3,5178
Hamilton 11	6,0190	4,3982
Cambridge	4,7037	
Kinleith	10,8801	
Hamilton 33	4,2064	4,2064
Waikino	12,2909	3,2321
Hinuera	6,4905	
Te Awamutu	4,9943	
PCGSS	1,3336	1,3783

Fonte: Autoria Própria.

Um fato interessante a se observar é que para cada bloco agregado tem-se uma subestação com erro elevado e ao realizar a agregação, os resultados obtidos fornecem uma melhora considerável.

Figura 21 - Previsão da carga agregada real e carga agregada prevista pela rede ARTMAP *Fuzzy* para análise 7 para os blocos agregados: a) Hamilton 11, Cambridge e Kinleith e b) Waikino, Hinuera e Te Awamutu.



Fonte: Autoria Própria.

A figura 21 apresenta a curva de carga agregada prevista pela rede ARTMAP *Fuzzy* referente à análise 6 e o valor de carga agregada real considerando dois blocos de agregações realizadas: a) Hamilton 11, Cambridge e Kinleith e b) Waikino, Hinuera e Te Awamutu.

Para todos os cálculos realizados na previsão agregada, foram utilizados os mesmos parâmetros na rede neural. Os valores são apresentados na tabela 13:

Tabela 13 - Parâmetros utilizados para a previsão global da carga agregada.

ρ_{ab}	ρ_a	ρ_β	β	α	ε
1,0000	0,9000	0,9000	1,0000	0,7000	0,0005

Fonte: Autoria Própria.

4.5 Resultados da Previsão Multinodal Através do Retorno da Carga Agregada

A metodologia desenvolvida por Abreu et. al (ABREU, 2018) mostrou que a agregação de cargas elétricas utilizadas na previsão de carga elétrica multinodal apresenta vantagens em relação ao tempo de processamento e uma melhor precisão dos resultados obtidos para previsão global. Porém, os resultados obtidos através desta metodologia não fornecem a previsão local de cada subestação agregada. Para o sistema é primordial saber a carga elétrica necessária em cada subestação. Então, foi realizada a desagregação, ou seja, a previsão de carga elétrica para as subestações que foram agregadas.

Para realizar o estudo do comportamento do retorno das cargas agregadas, foram selecionadas três das sete análises mencionadas anteriormente, sendo elas as análises: 5, 6 e 7.

Serão apresentados os resultados comparativos das cargas quando realizada a previsão local, a previsão com as cargas agregadas e a previsão local realizada por meio das cargas desagregadas.

- Análise do retorno das cargas agregadas para “Análise 5”**

Na tabela 14 são mostrados os resultados obtidos para a análise 5.

Tabela 14 - Valores do erro percentual médio absoluto das subestações individuais, agregadas e da metodologia proposta para análise 5.

Subestação	MAPE (%) Locais	MAPE (%) com Agregação	MAPE (%) Metodologia Proposta
------------	-----------------	------------------------	----------------------------------

Kopu	5,9102	5,9102	5,9102
Waihou	3,5178	3,5178	3,5178
Hamilton 11	6,0190	4,3982	4,6677
Cambridge	4,7037		3,9570
Kinleith	10,8801		6,5646
Hinuera	6,4905	6,4905	6,4905
Waikino	12,2909	3,0596	4,8258
Te Awamutu	4,9943		5,7927
Hamilton 33	4,2064		4,7256
PCGSS	1,3336	2,5740	2,9747

Fonte: Autoria Própria.

É possível observar que quando se realiza o retorno para as cargas locais, o MAPE para as subestações Te Awamutu e Hamilton 33 são maiores, porém, próximos do que quando estavam desagregadas, enquanto houve uma redução significativa para as demais subestações.


Os parâmetros utilizados na rede neural ARTMAP *Fuzzy* para as subestações que foram desagregadas, encontram-se na tabela 15.

Tabela 15 - Valores dos parâmetros da rede neural ARTMAP *Fuzzy* para realizar o retorno das subestações da análise 5.

Subestação	ρ_{ab}	ρ_a	ρ_b	β	α	ε
Hamilton 11	1,000000	0,900000	0,999200	1,000000	0,900000	0,500000
Cambridge	1,000000	0,900000	0,999900	1,000000	0,990000	0,900000
Kinleith	1,000000	0,900000	0,999599	1,000000	0,990000	0,050000
Waikino	1,000000	0,900000	0,999000	1,000000	0,700000	0,000500
Te Awamutu	1,000000	0,900000	0,995000	1,000000	0,070000	0,900000
Hamilton 33	1,000000	0,900000	0,99200	1,000000	0,100000	0,500000

Fonte: Autoria Própria.

Figura 22 - Curvas de carga elétrica local real, prevista com retorno e prevista sem retorno para análise 5.




Fonte: Autoria Própria.

Na figura 22 são apresentados os gráficos das curvas locais individuais de cada uma das subestações utilizando a metodologia proposta (retorno das cargas agregadas). Também estão esboçadas no gráfico as curvas locais reais e as curvas locais previstas antes da realização das agregações.

É possível notar que quando comparado os 48 pontos de cada curva de carga local real com as curvas de cargas com retorno e as curvas de cargas previstas iniciais (sem retorno), as curvas de cargas obtidas pela metodologia proposta acompanha melhor a curva da carga real, principalmente quando observado o gráfico da subestação Kinleith, o qual em todos os trabalhos que utilizaram o mesmo banco de dados, sempre foi a subestação mais difícil de prever.

A figura 23 mostra o comportamento da curva da carga global quando realizado o retorno para cada subestação.

Figura 23 - Curvas de carga elétrica global real e prevista pela rede neural ARTMAP Fuzzy através da soma das previsões de cargas multinodais via análise 5.



Fonte: Autoria Própria.

- **Análise do retorno das cargas agregadas para “Análise 6”**

Na tabela 16 é mostrado o resultado do retorno individual das subestações para análise 6.

Pode-se verificar que mesmo quando realizado o retorno para as subestações, a subestação Hinuera foi a única que apresentou um valor de erro maior, quando comparado com o resultado obtido antes da agregação, e ainda foi possível notar que o MAPE da PCGSS, dado

no retorno, foi menor tanto quando estava agregada, quanto o resultado obtido antes de realizar as agregações.

Tabela 16 - Valores do erro percentual médio absoluto das subestações individuais, agregadas e da metodologia proposta para análise 6.

Subestação	MAPE (%) Locais	MAPE (%) com Agregação	MAPE (%) Metodologia Proposta
Kopu	5,9102	5,9102	5,9102
Waihou	3,5178	3,5178	3,5178
Hamilton 11	6,0190	4,3982	4,6677
Cambridge	4,7037		3,9570
Kinleith	10,8801		6,5646
Hamilton 33	4,2064	4,2064	4,2064
Waikino	12,2909	3,2321	4,0280
Hinuera	6,4905		7,8663
Te Awamutu	4,9943		4,6354
PCGSS	1,3336	1,3783	1,2469

Fonte: Autoria Própria.

Os parâmetros que foram utilizados na rede neural ARTMAP *Fuzzy* para o retorno das subestações estão descritos na tabela 17.

Tabela 17 - Valores dos parâmetros da rede neural ARTMAP *Fuzzy* para realizar o retorno das subestações da análise 6.

Subestação	ρ_{ab}	ρ_a	ρ_b	β	α	ε
Hamilton 11	1,000000	0,900000	0,999200	1,000000	0,900000	0,500000
Cambridge	1,000000	0,900000	0,999900	1,000000	0,990000	0,900000
Kinleith	1,000000	0,900000	0,999599	1,000000	0,990000	0,050000
Waikino	1,000000	0,900000	0,999000	1,000000	0,700000	0,000500
Hinuera	1,000000	0,900000	0,995000	1,000000	0,700000	0,000500
Te Awamutu	1,000000	0,900000	0,999490	1,000000	0,050000	0,500000


Fonte: Autoria Própria.

Na figura 24, estão esboçadas as curvas relacionadas ao retorno das cargas para cada uma das subestações da análise 6, utilizando a metodologia proposta e comparando-as com as cargas locais reais e as cargas locais previstas iniciais (sem agregação e retorno).

O desempenho para retorno da PCGSS pode ser visto na figura 25. Por meio da Figura 24, é possível observar que as curvas obtidas como resultado da metodologia proposta


acompanham de melhor forma as curvas reais, em relação às curvas locais obtidas inicialmente (sem retorno), principalmente se tratando das subestações Waikino e Kinleith.

Figura 24 - Curvas de carga elétrica local real, prevista com retorno e prevista sem retorno para análise 6.



Fonte: Autoria Própria.

Figura 25 - Curvas de carga elétrica global real e prevista pela rede neural ARTMAP *Fuzzy* através da soma das previsões de cargas multinodais via análise 6.



Fonte: Autoria Própria.

- **Análise do retorno das cargas agregadas para “Análise 7”**

Na tabela 18 estão os resultados obtidos para retorno individual das subestações da análise 7.

Tabela 18 - Valores do erro percentual médio absoluto das subestações individuais, agregadas e da metodologia proposta para análise 7.

Subestações	MAPE (%) Locais	MAPE (%) com agregação	MAPE (%) metodologia proposta
Kopu	5,9102	5,9102	5,9102
Waihou	3,5178	3,5178	3,5178
Hamilton 11	6,0190	4,7561	4,9860
Hamilton 33	4,2064		3,8915
Cambridge	4,7037		4,4394
Te Awamutu	4,9943	4,9943	4,9943
Waikino	12,2909	3,7562	5,5658
Hinuera	6,4905		4,5146
Kinleith	10,8801		8,6958
PCGSS	1,3336	1,4801	3,0535

Fonte: Autoria Própria.

É possível observar que todos os resultados, quando utilizada a metodologia proposta, apresentaram um ganho de desempenho quando comparados com as cargas previstas de cada uma das subestações obtidas inicialmente (sem a agregação e retorno).

Os parâmetros da RNA ARTMAP *Fuzzy* utilizados para as subestações que foram desagregadas, encontram-se na tabela 19.

Tabela 19 - Valores dos parâmetros da rede neural ARTMAP *Fuzzy* para realizar o retorno das subestações da análise 7.


Subestação	ρ_{ab}	ρ_a	ρ_b	β	α	ε
Hamilton 11	1,0000	0,9000	0,9999	1,0000	0,0500	0,0005
Hamilton 33	1,0000	0,9000	0,9900	1,0000	0,0500	0,0005
Cambridge	1,0000	0,9000	0,9909	1,0000	0,6000	0,0005
Waikino	1,0000	0,9000	0,9992	1,0000	0,0500	0,0005
Hinuera	1,0000	0,9000	0,9900	1,0000	0,0700	0,5900
Kinleith	1,0000	0,9000	0,9992	1,0000	0,6000	0,0005

Fonte: Autoria Própria.

Na figura 26, estão os gráficos das curvas das cargas locais reais, das curvas das cargas locais previstas iniciais (sem agregação e retorno) e das cargas previstas utilizando a metodologia proposta (com agregação e retorno), e na figura 27 é apresentada a curva de carga global real e prevista PCGSS.


Observando os gráficos da figura 26, é possível notar que quando comparados os 48 pontos das curvas de cargas locais reais de cada subestação com as curvas locais de cargas previstas com retorno e as curvas de cargas locais previstas sem retorno, as curvas de cargas obtidas pela metodologia proposta apresenta um ganho de desempenho em todos os casos para a análise 7, principalmente quando observadas as curvas do gráfico da subestação Kinleith.

Figura 26 - Curvas de carga elétrica local real, prevista com retorno e prevista sem retorno para análise 7.



Fonte: Autoria Própria.

Figura 27 - Curvas de carga elétrica global real e previstas pela rede neural ARTMAP *Fuzzy* através da soma das previsões de cargas multinodais via análise 7.



Fonte: Autoria Própria.

A Figura 27 apresenta as curvas de carga global real e obtida pela soma das cargas das previsões de subestações individuais e subestações agregadas, respectivamente, pela Análise 7.

5 CONCLUSÃO

A utilização de sistemas inteligentes tem se mostrado muito eficiente para problemas de previsão de cargas elétricas, uma vez que é capaz de otimizar a distribuição de energia para as subestações, bem como para os consumidores finais, impactando na redução de desperdícios e, consequentemente, numa melhoria dos lucros das distribuidoras.

Para o presente trabalho, foi utilizada a rede ARTMAP *Fuzzy* para prever as cargas globais e locais a curto prazo, 24 horas à frente, de uma companhia de energia elétrica da Nova Zelândia. Com os dados ofertados dessa companhia, foi possível analisar a previsão de cargas multinodais, por meio da previsão de cargas elétricas agregadas.

As previsões das cargas calculadas para as subestações resultaram em erros entre 3,5178% a 12,2909%, tendo a previsão das cargas global gerada a partir da soma das subestações, apresentado um erro percentual médio absoluto em torno de 1,3336%. Assim, observados e analisados tais resultados, percebeu-se a necessidade de investigar uma maneira que os otimizassem.

A previsão de cargas multinodais aliada ao fator de participação mostrou-se muito eficaz, tendo resultados expressamente significativos e precisos.

Analisando os gráficos dos fatores de participação de cada uma das subestações, observou-se que uma subestação com menor fator de participação e uma outra com um maior deixava o sistema em equilíbrio.

Para encontrar o equilíbrio do sistema, foram realizadas as agregações das cargas, sendo testadas várias formas de agregá-las, seja pela proximidade, pela região, pelas localidades, pelo distanciamento, entre outros, e foi possível observar que os melhores resultados ocorreram quando respeitado o diagrama elétrico, pois os que não respeitavam tiveram resultados desfavoráveis.

Também foi possível notar que entre as subestações de Hamilton 33 e Hamilton 11 existe um transformador. Este fato é desfavorável, pois possibilita que qualquer agregação da subestação Hamilton 33 com as demais subestações do sistema gerem erros superiores a 3,5%.

As Análises, 4, 5 e 6 são compostas de mais de um bloco, sendo um bloco agregado, em comum, composto pelas subestações de Hamilton 11, Cambridge e Kinleith. A análise 5 obteve um resultando maior na PCGSS, comparado com as PCGSS das outras, visto que na análise em questão o segundo bloco agregado utiliza a subestação de Hamilton 33.

No entanto, verificado que a agregação das cargas obtidas apresentou resultados significativos, fez-se necessário retornar os valores para as cargas locais, o que gerou reduções

significativas ou até mesmo aumentou em menos de 1% o MAPE, quando comparados com os resultados das previsões locais.

As simulações realizadas para o retorno de cada subestação, obteve desempenhos melhores quando comparado com a carga prevista individual de cada subestação, sendo conferido pelos valores do MAPEs e pelos gráficos verificando a proximidade que a curva com retorno fica da carga global real.

Em consequência, obteve-se erros satisfatórios de PCGSS, obtendo MAPEs de valores máximos para a previsão da carga de 3,5689% e valores mínimos de 1,1750%. Estes valores foram consideráveis quando tratados de previsões de cargas no horizonte de curto prazo, garantindo que a técnica utilizada fosse eficiente.

5.1 Trabalho Publicado

ABREU, T.; MOREIRA JUNIOR, J.; MINUSSI, CARLOS R.; LOTUFO, A. D. P.; LOPES, M. L. M.. *Short-Term Multinodal Load Forecasting Using a Fuzzy-ARTMAP Neural Network*. In: **IEEE PES Innovative Smart Grid Technologies Latin América**, 2019. Gramado-RS.

5.2 Trabalho Aceito

MOREIRA JUNIOR, J. R.; ABREU, T.; MINUSSI, CARLOS R.; LOPES, M. L. M.. *Previsão de Cargas Multinodais Realizada Através da Análise da Previsão de Cargas Elétricas Agregadas*. In: **XXIII Congresso Brasileiro de Automática (CBA)**, 2020.

5.3 Sugestões para Trabalhos Futuros

Dando continuidade à proposta trabalhada nesta pesquisa, tem-se que a metodologia apresentada pode ser melhorada, e como sugestão para trabalhos futuros os seguintes tópicos são apresentados:

- Utilizar técnicas de otimização para encontrar parâmetros idênticos/similares para realizar as previsões multinodais;
- Utilizar parâmetros de tempo para analisar o processamento da metodologia.

- Realizar a previsão das cargas locais como globais (cada carga individualmente, sem depender da CG) e comparar.
- Comparar a ARTMAP *Fuzzy* com a GRNN e a MLP.
- Sistematizar a agregação das cargas locais (de acordo com o Diagrama Elétrico).
- Normalizar o FPCG após a previsão, de modo que a soma dos FPCGs seja unitária.

REFERÊNCIAS

- ABREU, Thays *et al.* Electrical Customer Profile Using Fuzzy Logic Theory. **IEEE Latin America Transactions**, [s. l.], v. 18, n. 8, p. 1353-1361, 2020.
- ABREU, T.; MOREIRA JUNIOR, J.; MINUSSI, CARLOS R. ; LOTUFO, A. D. P. ; LOPES, M. L. M. Short-Term Multinodal Load Forecasting Using a Fuzzy-ARTMAP Neural Network. In: IEEE PES INNOVATIVE SMART GRID TECHNOLOGIES LATIN AMÉRICA, 2019, Gramado. **Anais [...]** Gramado: IEEE PES Innovative Smart Grid Technologies Latin América, 2019.
- ABREU, T.; AMORIM, A. J.; SANTOS-JUNIOR, C. R.; A. D. P. LOTUFO, A. D. P.; MINUSSI, C. R. Multinodal Load Forecasting for Distribution Systems Using a Fuzzy-ARTMAP Neural Network. **Applied Soft Computer**, [s. l.], v. 71, p. 307-316, 2018.
- AL-KANDARI, A. M.; SOLIMAN, S. A. and EL-HAWARY, M. E. *Fuzzy short term electric load forecasting*. **Electric Power & Energy Systems**, [s. l.], v. 26, n. 2, p. 111-122, 2004.
- ALTRAN, A. B. **Sistema Inteligente para Previsão de Cargas Elétricas Multinodal em Sistemas Elétrico de Potência**. 2010. 87 f. Tese (Doutorado) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2010.
- ALVES, W. R. **Modelos para Previsão de Carga a Curto Prazo Através de Redes Neurais Artificiais com Treinamento Baseado na Teoria da Informação**. Tese (Mestrado em Engenharia Elétrica) - Universidade Federal do Pará, Instituto de Tecnologia, Belém, 2011.
- 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**, [s. l.], v. 179, 2020.
- ANTUNES, J. F. **Previsão de Carga Multinodal Usando a Rede Neural ART-ARTMAP Fuzzy**. Tese (Doutorado em Engenharia Elétrica), Universidade Estadual de Paulista “Júlio de Mesquita Filho”, Ilha Solteira, 2013.
- BARRETO, M. N. **Análise e Previsão de carga Crítica Ativa e Reativa do Sistema Elétrico Brasileiro**. 2017. Tese (Doutorado em Engenharia Elétrica), Universidade Estadual de Campinas, Campinas, 2017.
- BENDER, E. A. **Mathematical methods in artificial intelligence**. Los Alamitos: IEEE Computer Society, 1996.
- BORDIGNON, Sérgio. **Metodologia para Previsão de Cargas de Curtíssimo Prazo Considerando Variáveis Climáticas e Auxiliando na Programação de Despacho de Pequenas Centrais Hidrelétricas**. 2012. Tese (Mestrado em Engenharia Elétrica), Universidade Federal do Pampa, Alegrete, 2012.
- BOX, G. E.; JENKINS, G. M. **Times Series Analysis: Forecasting and Control**. Holden-Day, 1976.
- CARPENTER, G. A. *et al.* 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.

CDS-Centralized Dataset, Electricity commission for the load dataset. New Zealand: [s. l.], 2010.

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 resonance theory: how a brain learns to consciously attend, learn, and recognize a changing world. **Neural Networks**, New York, v. 37, p. 1–47, 2013.

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

LOPES, M. L. M. **Desenvolvimento de Redes Neurais para Previsão de Cargas Elétricas de Sistemas de Energia Elétrica.** 2005. Tese (Doutorado em Engenharia Elétrica), Universidade Estadual Paulista “Júlio de Mesquita Filho”, Ilha Solteira, 2005.

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**, v. 44, n. 9, pp.1525-1534, 2003.

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. Thesis (Master) - Department of Engineering Physics and Mathematics, Helsinki University of Technology, Helsinki, 1998.

NOSE FILHO, K. **Previsão de carga multinodal utilizando redes neurais de regressão generalizada.** 2010. Tese (Mestrado em Engenharia Elétrica), Universidade Estadual de Paulista “Júlio de Mesquita Filho”, Ilha Solteira, 2010.

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, 2011.

O'DONOVAN, T. M. Short Term Forecasting: An introduction to the Box-Jenkins approach. New York: John Wiley & Sons, 1983.

PANDIAN, S. C.; DURAISWAMY, K.; RAJAN, C. C. A.; KANAGARAJ, N. Fuzzy approach for short term load forecasting. **Electric Power Systems Research**, Lausanne, v. 76, n. 6/7, p. 541-548, 2006.

PIRES, C. L. *et al.* Previsão de carga para curtíssimo prazo considerando a influência das variáveis climáticas. In: SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS – SBSE, 2016, Natal. **Anais [...]** Natal: [s. n.], 2016.

RÊGO, L. **Estratégia para predição de consumo de energia elétrica de curto prazo: uma abordagem baseada em densificação com mean shift para tratamento de dias Especiais.** 2016. Tese (Doutorado em Engenharia Elétrica), Universidade Federal do Pará, Belém, 2016.

RODRIGUES, D. D. **Previsão de fornecimento de energia elétrica: um estudo de caso do ponto de vista do barramento**. 2002. Tese (Mestrado em Engenharia Elétrica), Universidade Federal de Minas Gerais, Belo Horizonte, 2002.

RUAS, G. I. S. *et al.* **Previsão de demanda de energia elétrica utilizando redes neurais artificiais e support vector regression**. Rio de Janeiro: UFRJ, 2004.

SALGADO, R. M. **Um modelo de previsão de carga por barramento**. 2004. Tese (Mestrado em Engenharia Elétrica), Universidade Estadual de Campinas, Campinas, 2004.

SUGANTHI, L; SAMUEL, A. A. Energy models for demand forecasting - A review. **Renewable and Sustainable Energy Reviews**, v. 16, n. 2, p. 1223-1240, 2012.

SRINIVASAN, D.; TAN, S. S.; CHANG, C.-S. S.; CHAN, E. K. Practical Implementation of a Hybrid Fuzzy Neural Network for One-Day-Ahead Load Forecasting. **IEEE Proceedings Generation, Transmission And Distribution**, New York, v. 145, n. 6, p. 687-692, 1998. Disponível em: <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=749170>. Acesso em: 11 abr. 2013.

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.

VEHVILÄINEN, I; KEPPO, J. Managing electricity market price risk. **European Journal of Operational Research**, Amsterdam, v. 145, n. 1, p. 136-147, 2003.

YALCINOZ, T. and EMINOGLU, U. Short term and medium term power distribution load forecasting by neural networks. **Energy Conversion and Management**, Article in Press (Available Online), p. 1-13, 2004.

ZADEH, L.A. Fuzzy sets. **Information and Control**, [s. l.], v. 8, p. 338-353, 1965.

APÊNDICE A

A.1 Previsão de Carga Multinodal por Rede Neural ARTMAP *Fuzzy*


Utilizar um sistema inteligente para prever a demanda de cargas tem sido uma ótima ferramenta encontrada na literatura. As redes da família ART (*Adaptive Resonance Theory*) possuem como principal característica a capacidade de aprender algo novo, sem perder o conhecimento adquirido anteriormente. Tal habilidade é conhecida como dilema da plasticidade/estabilidade, no qual sugere que o sistema seja flexível e estável para novos conhecimentos, a fim de preservar o conhecimento já adquirido.

A Rede Neural ARTMAP *Fuzzy* diferencia-se das demais redes da família ART por utilizar em seus cálculos a teoria dos conjuntos *Fuzzy*, capazes de aprender categorias estáveis em resposta a padrões de entradas, tanto analógicos como binários, e pelo treinamento supervisionado.

A.2 Algoritmo da Rede Neural ARTMAP *Fuzzy*

A rede ARTMAP *Fuzzy* é composta por dois módulos ART *Fuzzy*: o ART_a *Fuzzy* e o ART_b *Fuzzy*, que possuem a mesma estrutura da rede neural ART *Fuzzy*, exceto que a ART_a *Fuzzy* inclui um campo de mapeamento que controla o treinamento de um mapa associativo de categorias de reconhecimento da ART_a para categorias de reconhecimento da ART_b. O campo de mapeamento controla a regra *Match Tracking*, que aumenta o parâmetro de vigilância da rede ART_a por uma quantia mínima necessária para corrigir um erro preditivo [CARPENTER *ET AL.*, 1992; RAVEENDRAN *ET AL.*, 2000]. A figura 1 detalha a arquitetura de ARTMAP *Fuzzy*.

Figura 28 - Rede ARTMAP Fuzzy.



Fonte: Lopes (2005).

Para o módulo ART_a , $x^a = [x_1^a \dots x_{2Ma}^a]$ denota o vetor de saída do campo F_1^a ; $y^a = [y_1^a \dots y_{2Na}^a]$ denota o vetor de saída do campo F_2^a e $w_j^a = [w_{j1}^a \dots w_{j,2Ma}^a]$ denota o j -ésimo vetor peso. Já para o módulo ART_b , $x^b = [x_1^b \dots x_{2Mb}^b]$ denota o vetor de saída do campo F_1^b ; $y^b = [y_1^b \dots y_{2Nb}^b]$ denota o vetor de saída do campo F_2^b e $w_k^b = [w_{k1}^b \dots w_{k,2Mb}^b]$ denota o k -ésimo vetor peso. Para o Mapa de Campo, $x^{ab} = [x_1^{ab} \dots x_{Nb}^{ab}]$ denota o vetor de saída do campo F^{ab} e $w_j^{ab} = [w_{j1}^{ab} \dots w_{j,Nb}^{ab}]$ denota o vetor peso que parte do j -ésimo nó F_2^a para F^{ab} (CARPENTER, GROSSBERG, *et al.*, 1992).

Os parâmetros que atuam no processo de execução (treinamento e diagnóstico) da rede ARTMAP Fuzzy são definidos da seguinte forma:

- Parâmetro de Escolha α ($\alpha > 0$): responsável pela seleção das categorias;
- Taxa de Aprendizagem β ($\beta \in [0,1]$): controla a velocidade de aprendizagem da rede;

- Parâmetro de Ressonância dos módulos ART_a , ART_b e Inter-ART (ρ_a , ρ_b e $\rho_{ab} \in [0,1]$): responsável pelo número de categorias criadas, isto é, controla a ressonância da rede.

O algoritmo sucinto da rede neural ARTMAP Fuzzy consiste, basicamente, nos seguintes passos [Carpenter *et al.* 1992]:

1º passo - Os vetores de entrada e saída esperadas são denominados pelos vetores $a = [a_1 \ a_2 \ a_3 \ \dots \ a_{Ma}]$ e $b = [b_1 \ b_2 \ b_3 \ \dots \ b_{Mb}]$ respectivamente, de dimensão M . Estes vetores são normalizados pela equação (1) visando evitar a proliferação de categorias (além do mínimo necessário), por conseguinte (CARPENTER *et al.*, 1992; GEORGIOPOULOS *et al.*, 1996), tem-se:

$$\underline{a} = \frac{a}{|a|} \quad \text{e} \quad \underline{b} = \frac{b}{|b|} \quad (1)$$

Sendo que:

$\underline{a}$: vetor de entrada normalizado.

$|a| : \sum_{i=1}^M |a_i|$ (norma – 1)

$\underline{b}$: vetor de saída normalizado.

$|b| : \sum_{i=1}^M |b_i|$ (norma – 1)

2º passo – Codificação do vetor de entrada e saída, equação (2):

$$I_a = \begin{bmatrix} \underline{a} & \underline{a}^c \end{bmatrix} \quad \text{e} \quad I_b = \begin{bmatrix} \underline{b} & \underline{b}^c \end{bmatrix} \quad (2)$$

Onde:

$\underline{a}_i^c : 1 - \underline{a}_i$

$\underline{b}_i^c : 1 - \underline{b}_i$

Sendo $\underline{a}_i$ e $\underline{b}_i$ o complementar normalizado

O pré-processador do complemento, transforma o vetor M-dimensional em um vetor de dimensão 2M, dado por:

$$I_a = A = [\underline{a} \ \underline{a_i^c}] = [\underline{a_1} \ \underline{a_2} \ \dots \ \underline{a_M} \ \underline{a_1^c} \ \underline{a_2^c} \ \dots \ \underline{a_M^c}];$$

e

$$I_b = B = [\underline{b} \ \underline{b_i^c}] = [\underline{b_1} \ \underline{b_2} \ \dots \ \underline{b_M} \ \underline{b_1^c} \ \underline{b_2^c} \ \dots \ \underline{b_M^c}].$$

3º passo - Inicialização dos pesos.

A inatividade da categoria é representada pelo peso unitário, representado abaixo:

$$w_{j1}^a(0) = w_{k1}^b(0) = w_j^{a \ b}(0) = 1$$

4º passo - Escolha da categoria vencedora em ART_a e ART_b pela equação (3):

$$T_j^a(I_a) = \frac{|I_a \wedge w_j^a|}{\alpha + |w_j^a|} \quad \text{e} \quad T_k^b(I_b) = \frac{|I_b \wedge w_k^b|}{\alpha + |w_k^b|} \quad (3)$$

Onde:

$\wedge$: operador AND Fuzzy, definido por: $(p \wedge q)_i = \min(p_i, q_i)$

$|\cdot|$: norma, calculada por: $|p| = \sum_{i=1}^M |p_i|$

Para qualquer vetor M-dimensional p e q.

Em ART_a ganha-se a categoria J com $T_J = \max\{T_j\}$ e índice mínimo J, e em ART_b ganha-se a categoria K com $T_K = \max\{T_k\}$ e índice mínimo K.

O vetor de atividade $y = [y_1 \ y_2 \ \dots \ y_N]$ da camada F2, sendo N a quantidade de categorias criadas. Assim, para a categoria j-ésima escolhida tem-se:

$$y_j = \begin{cases} 1, & \text{se } j = J \\ 0, & \text{se } j \neq J \end{cases}$$

5º passo - Depois de selecionar as categorias vencedoras, o teste de vigilância do módulo ART_b é feito, conforme a equação (4):

$$\frac{|I_b \wedge w_K^b|}{|I_b|} \geq \rho_b \quad (4)$$

Se a equação (4) for satisfeita, a ressonância é alcançada e os pesos são atualizados através da equação (5), caso contrário o reset ocorre, então o neurônio K é excluído do processo de busca e um novo neurônio vencedor é determinado. Se todos os neurônios forem rejeitados, a rede neural cria um novo neurônio.

$$w_K^{novo} = \beta (I_b \wedge w_K^{velho}) + (1 - \beta) w_K^{velho} \quad (5)$$

6º passo - Neste passo é realizado o teste de vigilância do módulo ART_a , determinado por meio da equação (6):

$$\frac{|I_a \wedge w_J^a|}{|I_a|} \geq \rho_a \quad (6)$$

Se a equação (6) for satisfeita, a ressonância para o módulo ART_a ocorre e verifica, através do *Match Tracking*, se os neurônios vencedores K e J são adequados, como descrito pela equação (7):

$$\frac{|y_j^b \wedge w_{JK}^{ab}|}{|y_j|} \geq \rho_{ab} \quad (7)$$

Se a ressonância ocorre no *Match Tracking*, o índice J vencedor é ativado, além disso, os índices J e K são confirmados e os pesos nos módulos ART_a e Inter-ART são atualizados por meio das equações (8) e (9), respectivamente.

$$w_J^{novo} = \beta (I_a \wedge w_J^{velho}) + (1 - \beta) w_J^{velho} \quad (8)$$

Sendo:

J : índice da categoria ativa;

w_j^{novo} : vetor peso atualizado;

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

$$w_{JK}^{ab} = 1$$

$$w_{jk}^{ab} = 0 \text{ , se } j \neq J ; k \neq K \quad (9)$$

Se a ressonância não ocorrer, a categoria atual é descartada e um ε adicional é acrescentado na equação 6 (parâmetro de vigilância) para excluir a categoria ART_a que não combinou com a categoria ART_b .

$$\rho_a = \frac{|I_a \wedge w_j^a|}{I_a} + \varepsilon \quad (10)$$