

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

ANDRÉIA BRASIL ALVES FERREIRA

**PREVISÃO DE CARGA MULTINODAL UTILIZANDO REDE NEURAL ARTMAP
EUCLIDIANA**



Ilha Solteira
2020

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ANDRÉIA BRASIL ALVES FERREIRA

PREVISÃO DE CARGA MULTINODAL UTILIZANDO REDE NEURAL ARTMAP EUCLIDIANA

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

Prof^ª. Dr^ª. Mara Lúcia Martins Lopes
Orientadora

FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

F383p Ferreira, Andréia Brasil Alves.
Previsão de carga multinodal utilizando Rede Neural ARTMAP Euclidiana /
Andréia Brasil Alves Ferreira. -- Ilha Solteira: [s.n.], 2020
76 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. Rede ARTMAP Euclidiana. 3. Previsão de Carga
Multinodal. 4. Distribuição de sistemas elétricos.


Raiane da Silva Santos

Supervisora Técnica de Saúde
Setor de Processamento de Informação e Documentação
Divisão Técnica de Biblioteca e Documentação
CEBIS - 9999

ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE ANDRÉIA BRASIL ALVES FERREIRA, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DA FACULDADE DE ENGENHARIA - CÂMPUS DE ILHA SOLTEIRA.

Aos 22 dias do mês de abril do ano de 2020, às 08:00 horas, no(a) Sala de Seminários I - Campus 3, reuniu-se a Comissão Examinadora da Defesa Pública, composta pelos seguintes membros: Prof^a. Dr^a. MARA LUCIA MARTINS LOPES - Orientador(a) do(a) Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira - UNESP, Prof. Dr. CARLOS ROBERTO MINUSSI do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP, Prof. Dr. CARLOS ROBERTO DOS SANTOS JÚNIOR do(a) Campus de Hortolândia / Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - IFSP, sob a presidência do primeiro, a fim de proceder a arguição pública da DISSERTAÇÃO DE MESTRADO de ANDRÉIA BRASIL ALVES FERREIRA, intitulada **PREVISÃO DE CARGA MULTINODAL UTILIZANDO REDE NEURAL ARTMAP EUCLIDIANA**. Após a exposição, a discente foi arguida oralmente pelos membros da Comissão Examinadora, tendo recebido o conceito final: APROVADA - x -. Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelos membros da Comissão Examinadora.

Prof^a. Dr^a. MARA LUCIA MARTINS LOPES

Prof. Dr. CARLOS ROBERTO MINUSSI

Prof. Dr. CARLOS ROBERTO DOS SANTOS JÚNIOR

DEDICATÓRIA

Dedico este trabalho a Deus, devo a Ele tudo o que sou. Aos meus pais Eniete e Silivaldo (*in memoriam*).

AGRADECIMENTOS

Primeiramente, agradeço a Deus por dar-me sabedoria, saúde, força e capacidade para concretizar este trabalho.

À Prof^a. Dr^a. Mara Lúcia Martins Lopes, minha eterna gratidão pela oportunidade e confiança ao longo do desenvolvimento desta pesquisa e também pela amizade, paciência e compreensão em todos os momentos.

À minha querida mãe Eniete que sempre me apoiou em meus estudos e esteve presente nos momentos mais difíceis.

Ao meu irmão André e à minha estimada amiga Patrícia pelo apoio, amizade e incentivo.

Aos colegas do laboratório SINTEL, em especial, Tânia, Haislan e Aline pelo conhecimento compartilhado e estímulo ao trabalho, meus sinceros agradecimentos.

Aos funcionários da FEIS UNESP que contribuíram de forma direta ou indireta para a elaboração desta pesquisa, dedico meus agradecimentos.

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

“A ciência é muito mais do que um corpo de conhecimento. É uma maneira de pensar. E isso é fundamental para o nosso sucesso. A ciência nos convida a aceitar os fatos, mesmo quando eles não estão de acordo com nossos preconceitos.”

Carl Sagan

RESUMO

A antecipação da demanda energética é um segmento imprescindível para os sistemas elétricos de potência, no que tange às atividades de operação e planejamento, haja vista que as previsões oportunizam elementos cruciais na tomada de decisão favorecendo diferentes ângulos desses sistemas. Essa pesquisa visa investigar o emprego das redes neurais artificiais na problemática da previsão de cargas elétricas de modo multinodal, isto é, observando-se diversos aspectos da rede elétrica. À vista disso, adotou-se uma arquitetura neural que se baseia na distância euclidiana e está fundamentada na teoria de ressonância adaptativa (ART), intitulada rede neural ARTMAP Euclidiana. No modelo neural aludido, foi aplicado um método que automatiza o ajuste dos parâmetros desta rede, visando obter resultados expressivos com rapidez, precisão e confiabilidade sem a necessidade de intervenção humana. Tendo em vista alcançar resultados com um horizonte preditivo de 24 horas à frente, a supracitada rede neural foi utilizada em diferentes módulos de um Sistema Previsor de Cargas da Subestação (SPCS) que processa as informações de cada subestação de forma particularizada. Desta forma, para avaliar a efetividade da metodologia proposta neste estudo, utilizaram-se dados históricos de cargas elétricas extraídos de um subsistema de distribuição de energia da *New Zealand Electrical Company*, do qual, foram aplicadas ao método proposto nesta pesquisa, nove subestações que compõem esse sistema de energia, bem como, a carga global do referido sistema elétrico.

Palavras-chave: Redes Neurais Artificiais. Rede ARTMAP Euclidiana. Previsão de Carga Multinodal. Distribuição de Sistemas Elétricos.

ABSTRACT

Anticipating energy demand is essential for the planning and operation of electric power systems since predictions highlight important points for decision-making, which improves different angles of these systems. Therefore, this research aims to investigate the use of artificial neural networks in the problem of forecasting electric charges in a multinodal way by observing several aspects of the electrical network. A neural architecture was adopted based on Euclidean distance and on the adaptive resonance theory (ART), named ARTMAP Euclidean neural network. In this neural model, the method applied automates the adjustment of the parameters of this network, aiming to obtain expressive results with speed, precision and reliability without requiring human intervention. In order to achieve results with a predictive horizon of 24 hours ahead, neural network was used in different modules of a Substation Load Prediction System (SPCS) that processes the information of each substation in a particular way. Historical data of electrical charges were used to evaluate the effectiveness of the methodology proposed in this study. These data were collected from New Zealand Electrical Company, which nine substations comprise its energy system, as well as the overall load of its electrical system energy distribution subsystem, and then, they were applied to the method proposed in this research.

Keywords: Artificial Neural Networks. Euclidean ARTMAP Neural Network. Multinodal Load Forecasting. Electrical Distribution Systems.

LISTA DE FIGURAS

Figura 1	- Fluxograma de um sistema elétrico de potência.....	23
Figura 2	- Desenho de um neurônio biológico e suas conexões.....	29
Figura 3	- Esquema do neurônio artificial de McCulloch e Pitts.....	30
Figura 4	- Esquema de um neurônio artificial.....	31
Figura 5	- Quadro de exemplos de funções de ativação.....	31
Figura 6	- Esquema com principais topologias das RNAs.....	32
Figura 7	- Esquema simplificado da família ART.....	35
Figura 8	- Esquema da arquitetura da rede neural ART.....	37
Figura 9	- Representação geométrica em hiper-retângulos.....	38
Figura 10	- Esquema simplificado da rede neural ARTMAP.....	40
Figura 11	- Representação geométrica em hiper-esferas.....	41
Figura 12	- Fluxograma do algoritmo da RNA ARTMAP Euclidiana.....	46
Figura 13	- Esquema de sistema previsor de carga multinodal.....	47
Figura 14	- Esquema do deslocamento de janelas.....	49
Figura 15	- Esquema do modelo da previsão proposto.....	50
Figura 16	- Imagem da localização geográfica das subestações.....	51
Figura 17	- Fluxograma da RNA ARTMAP Euclidiana com ajuste automático de parâmetros.....	53
Figura 18	- Curva de carga real e prevista da carga global.....	55
Figura 19	- Conjunto de curvas de cargas previstas por subestação.....	55
Figura 20	- Curva de carga global real e prevista pelo somatório das subestações....	59

LISTA DE QUADROS

Quadro 1	- Fatores exógenos que influenciam a carga elétrica.....	26
Quadro 2	- Parâmetros da Rede Neural ARTMAP Euclidiana.....	42
Quadro 3	- Dados exógenos utilizados no conjunto de entrada da rede RNA ARTMAP Euclidiana.....	48
Quadro 4	- Divisão do banco de dados.....	52

LISTA DE TABELAS

Tabela 1	- Parâmetros utilizados no sistema previsor global.....	54
Tabela 2	- Parâmetros utilizados por subestação.....	54
Tabela 3	- Resultados obtidos no sistema previsor global.....	57
Tabela 4	- Resultados obtidos no sistema previsor por subestação.....	57
Tabela 5	- Quantidade de neurônios.....	58
Tabela 6	- Comparação entre as cargas globais.....	59
Tabela A.1	- Carga global real e prevista.....	70
Tabela A.2	- Cargas reais por subestação.....	71
Tabela A.3	- Cargas previstas por subestação.....	72
Tabela A.4	- Carga global real e carga global prevista pela soma das subestações....	73

LISTA DE SIGLAS E ABREVIATURAS

RNA	Redes Neurais Artificiais
SEP	Sistema Elétrico de Potência
ST	Sistema de Transmissão
SPCS	Sistema Previsor de Cargas de Subestação
SPCG	Sistema Previsor de Cargas de Global
ARIMA	<i>Auto Regressive Integrated Moving Average</i>
ART	Teoria da Ressonância Adaptativa (<i>Adaptive Resonance Theory</i>)
ARTMAP	<i>Adaptive Resonance Theory – Supervised Predictive Mapping</i>
MAPE	Erro Percentual Absoluto Médio (<i>Mean Absolute Percentage Error</i>)

LISTA DE SÍMBOLOS

F_0	Camada que representa o vetor de entrada.
F_1	Camada de comparação.
F_2	Camada de reconhecimento.
ρ	Parâmetro de vigilância.
ρ_a	Parâmetro de vigilância do módulo ART_a .
ρ_b	Parâmetro de vigilância do módulo ART_b .
ρ_{ab}	Parâmetro de vigilância do módulo inter-ART.
β	Parâmetro taxa de treinamento.
α	Parâmetro de escolha.
ε	Ajuste do parâmetro de vigilância do módulo ART_a .
w	Matriz de pesos.
w^a	Matriz de pesos do módulo ART_a .
w^b	Matriz peso do módulo ART_b .
w^{ab}	Matriz peso do módulo inter-ART.
I_j^a	Vetor de entrada do módulo ART_a .
I_k^b	Vetor de entrada do módulo ART_b .
T_j	Função de escolha.
T_j^a	Função de escolha do módulo ART_a .
T_k^b	Função de escolha do módulo ART_b .
J	Categoria ativa do módulo ART_a .
K	Categoria ativa do módulo ART_b .
y_j^a	Vetor atividade do módulo ART_a .
y_k^b	Vetor atividade do módulo ART_b .
y_{jk}^{ab}	Vetor atividade do módulo inter-ART.
w_j^a	Vetor peso ativo no módulo ART_a .
w_K^b	Vetor peso ativo no módulo ART_b .
w_{JK}^{ab}	Vetor peso ativo no módulo inter-ART.

SUMÁRIO

1	INTRODUÇÃO.....	14
2	REVISÃO DE LITERATURA.....	18
3	PREVISÃO DE CARGAS ELÉTRICAS.....	22
3.1	PREVISÃO DE CARGA MULTINODAL.....	22
3.2	CLASSIFICAÇÃO DA PREVISÃO DE CARGAS ELÉTRICAS.....	25
3.3	FATORES QUE INFLUENCIAM A CARGA ELÉTRICA.....	26
3.4	TÉCNICAS DE PREVISÃO DE CARGA ELÉTRICA.....	27
3.4.1	Redes Neurais Artificiais.....	29
4	TEORIA DA RESSONÂNCIA ADAPTATIVA.....	35
4.1	REDE NEURAL ART.....	37
4.2	REDE NEURAL ARTMAP.....	39
4.3	REDE NEURAL ARTMAP EUCLIDIANA.....	40
5	REDE NEURAL EUCLIDIANA APLICADA AO PROBLEMA DE PREVISÃO DE CARGAS ELÉTRICAS.....	47
6	RESULTADOS E DISCUSSÕES.....	51
7	CONSIDERAÇÕES FINAIS.....	61
7.1	ARTIGO PUBLICADO.....	62
	REFERÊNCIAS.....	63
	APÊNDICE A – DADOS DE CARGAS.....	70

1 INTRODUÇÃO

Atualmente o mundo tem se caracterizado por uma necessidade energética cada vez maior, já que a estimativa é de um aumento de mais de 50% antes de 2030 se a demanda atual permanecer (CSIRO, 2007). Nesta perspectiva, a área de previsão de cargas elétricas torna-se essencial para garantir o bom funcionamento do mercado energético no futuro.

Os modelos de previsão são fundamentais para os sistemas elétricos de potência (SEPs), no que diz respeito à operação e planejamento dos mesmos, haja vista que as predições proveem informações indispensáveis na deliberação de diversos aspectos dos SEPs, como reserva e provimento de energia, projeção de receitas e despesas, segurança e amplificação do sistema, fluxo de potência, incluindo também decisões de compra e geração de energia elétrica, comutação de carga e desenvolvimento da infraestrutura (SHAHIDEHPOUR; YAMIN; LI, 2003).

A previsão de carga pode ser realizada de acordo com uma escala temporal, sendo a curto, médio e longo prazo, possuindo aplicações específicas no planejamento dos sistemas de energia elétrica. As predições de curto prazo são feitas de meia em meia hora ou horária e contempla o intervalo de um dia até uma semana, cuja importância está relacionada ao planejamento e operações diários dos SEPs. Quanto a previsão a médio prazo esta, por sua vez, abrange o período de algumas semanas a até alguns anos e traz dados essenciais para a manutenção e coordenação das unidades geradoras. Já a previsão a longo prazo, contempla um espaço de 10 a 20 anos e utiliza dados contendo as predisposições de consumo de um longo período de tempo, proporcionando informações importantes para o planejamento de expansão (AL-KANDARI *et al.*, 2004; MURTO, 1998).

Apesar do conhecimento prévio da demanda a ser suprida pelo SEP ser um fator fundamental para o desempenho efetivo do mercado energético, a imprecisão nas previsões pode resultar em um considerável aumento nos gastos operativos desses sistemas, causando grandes prejuízos à companhia elétrica. Assim, o adiantamento da carga a ser atendida deve ser viabilizado de forma rápida, precisa e confiável. Entretanto, diversos elementos exógenos, como circunstâncias meteorológicas eventuais (velocidade do vento, nebulosidade, variações de temperatura, etc.), dias atípicos (feriados, greves, etc.), entre outras variáveis que causam influência sobre as cargas, dificultam a previsão precisa (GROSS; GALIANA, 1987). Contudo, as informações históricas sobre os fatores de influência, permitem representar o comportamento da demanda energética a ser suprida e servem como dados de entrada para alguns métodos de previsão.

Visando melhorar a exatidão nos resultados das previsões, diversos modelos preditivos surgiram nas últimas décadas. Tradicionalmente, adotaram-se abordagens clássicas que exigem uma modelação anterior dos dados de entrada, como: regressão múltipla ou simples (MURTO, 1998; SFETSOS, 2003), alisamento exponencial (MOGHRAM; RAHMAN, 1989), filtro de Kalman (MOGHRAM; RAHMAN, 1989; MURTO, 1998), estimação de estado e os modelos ARIMA de Box & Jenkins (BOX; JENKINS, 1976; O'DONOVAN, 1983).

Com a chegada da inteligência artificial (IA), novos paradigmas surgiram visando obter resultados expressivos nas predições sem a necessidade de se conhecer a modelagem prévia das cargas. Esses métodos são conhecidos como Sistemas Especialistas, e incluem: sistemas *fuzzy*, programação evolutiva, redes neurais artificiais (RNAs) e alguns sistemas híbridos obtidos por meio da fusão destes algoritmos. As RNAs, devido a características como a facilidade de entendimento do modelo, simplicidade de elaboração e performance satisfatória, nos últimos anos, ocupam uma posição de destaque na resolução de diferentes problemáticas (SHAHIDEHPOUR; YAMIN; LI, 2003).

As redes neurais artificiais (RNAs) são concepções computacionais originadas a partir de uma inspiração biológica, mais especificamente, da organização neural do cérebro humano. Essa metodologia é composta por diversos elementos de processamento simples que são conectados entre si através de “sinapses artificiais”. (HAYKIN, 2008).

Atualmente existem na literatura especializada diversos modelos neurais, dentre eles, as arquiteturas baseadas na teoria da ressonância adaptativa (ART) (GROSSBERG, 1976). A família ART (CARPENTER; GROSSBERG, 1988) são modelos neurais desenvolvidos visando um melhor desempenho na solução de problemas de forma plástica e estável. Este trabalho emprega uma rede neural artificial baseada na teoria da ressonância adaptativa, intitulada ARTMAP Euclidiana, com o objetivo de realizar a previsões de curto prazo com horizontes de 24 horas à frente.

Neste trabalho, dá-se ênfase à previsão de carga multimodal ou previsão por barramento (PYNE, 1974), isto é, propõe-se uma abordagem cuja previsão deixa de limitar-se ao somatório das cargas que devem ser atendidas pelo SEP e passa a examinar os diferentes pontos que compõem o sistema de energia como subestações, transformadores, entre outros aspectos (CHEN *et al.*, 1996; SALGADO *et al.*, 2011). Desta forma, para realizar a previsão de carga multimodal, neste trabalho, é proposto um Sistema Previsor de Cargas de Subestação (SPCS), cujos módulos realizam a previsão das cargas de forma individualizada, através uma rede neural ARTMAP Euclidiana.

Nessa perspectiva, ressalta-se a relevância deste estudo, visto que, a maiorias dos trabalhos publicados na área de previsão de cargas elétricas abordam à previsão global, que compreende o somatório de todas as cargas. Além disso, no que se refere à aplicação da rede neural ARTMAP Euclidiana na problemática da demanda energética, não se encontram trabalhos na literatura especializada que abordem a emprego da referida arquitetura neural considerando vários nós do sistema elétrico de potência, isto é, de forma multinodal.

Este trabalho está dividido em sete capítulos, dos quais cada parte visa descrever e orientar quanto à metodologia que fundamenta esta pesquisa:

Capítulo 2. Revisão de Literatura: nesse capítulo são apresentadas as principais publicações correlatas da área de previsão de cargas elétricas, com ênfase ao contexto da previsão multinodal. Além de alguns trabalhos desenvolvidos utilizando arquiteturas neurais baseadas na distância euclidiana.

Capítulo 3. Previsão de Cargas Elétricas: neste capítulo são apresentados os principais conceitos de previsão de cargas elétricas, abordando os conceitos da previsão multimodal, a classificação temporal da previsão, os elementos que exercem influência no perfil da curva de carga e, também, os tipos de técnicas utilizadas para prever a carga elétrica.

Capítulo 4. Teoria da Ressonância Adaptativa: neste capítulo são fundamentados os principais conceitos da teoria da ressonância adaptativa (ART), abordando as arquiteturas que compõe a família ART, com ênfase na arquitetura neural ARTMAP Euclidiana como ferramenta para a previsão de carga multinodal.

Capítulo 5. Metodologia: nesta seção são descritas as metodologias propostas neste trabalho, aplicadas a um Sistema Previsor de Cargas de Subestação (SPCS).

Capítulo 6. Resultados e Discussões: este capítulo se destina a apresentação dos resultados obtidos com a aplicação das metodologias propostas no Capítulo 5, utilizando representações gráficas das curvas das cargas reais e previstas e a análise comparativa baseada nas métricas: Erro Máximo e Erro Percentual Médio Absoluto - MAPE (PARK; SHARKAWI; MARK II, 1991).

Capítulo 7. Conclusão e Trabalhos Futuros: nesse capítulo serão apresentados os resultados e conclusões obtidos por meio da metodologia proposta, abordando a relevância da ferramenta apresentada e, também, algumas sugestões de trabalhos futuros para a continuidade deste estudo.

Ao final, têm-se as referências bibliográficas utilizadas no desenvolvimento deste estudo e o Apêndice A que apresenta os dados históricos de cargas elétricas cedidos pela

Electricity Comission da Nova Zelândia, bem como as cargas obtidas por meio da metodologia proposta neste trabalho.

2 REVISÃO DE LITERATURA

Neste capítulo serão apresentados alguns trabalhos elaborados na área de previsão de carga, sobretudo estudos realizados considerando vários nós da rede elétrica, isto é, cuja pesquisa aborda o contexto da previsão multinodal. Também nesta seção, serão apresentados alguns trabalhos desenvolvidos utilizando arquiteturas neurais baseadas na distância euclidiana.

Na publicação AMBER *et al.*, 2018, é realizada uma análise da capacidade de previsão entre cinco diferentes metodologias inteligentes, sendo: regressão múltipla, programação genética, rede neural artificial, rede neural profunda e a máquina de vetor de suporte. Estes modelos de previsão foram aplicados em dados coletados durante cinco anos, onde foram observados cinco parâmetros diferentes: radiação solar, temperatura, velocidade do vento, umidade e índice de dias úteis. Os resultados demonstraram que a rede neural artificial supera todas as outras técnicas de previsão analisadas, obtendo um erro médio percentual absoluto (MAPE) de 6% enquanto as demais metodologias apresentaram valores superiores a 8%.

No trabalho de Chae *et al.* (2016), os autores propuseram um modelo para prever o consumo da eletricidade a cada 15 minutos e o pico diário em um complexo de edifícios comerciais. Nesta problemática, nove algoritmos foram analisados aplicando-se um coeficiente de correlação entre as variáveis e também uma medida de erro. Os resultados demonstraram que a rede neural bayesiana com algoritmo de treinamento de Levenberg-Marquardt foi à técnica cujo resultado se apresentou mais satisfatório, com erros percentuais médios absolutos inferiores a 4% para os dias úteis e menores que 9% para os finais de semana.

Em Peña *et al.* (2011), foram propostos quatro modelos para o problema da previsão a curto prazo com horizontes de 24 e 48 horas à frente, sendo: modelo auto-regressivo, ARIMA, rede neural perceptron multicamadas e rede Bayesiana. Essas metodologias foram aplicadas a previsão de carga de aparelhos de climatização e ventilação em prédios não residenciais, cujos resultados demonstraram que o modelo auto-regressivo se destacou de forma geral, contudo a rede neural apresentou melhor desempenho entre as demais técnicas analisadas.

Pyne (1974) propôs um método previsor de carga que considera vários barramentos da rede elétrica (multinodal), baseado em regressão múltipla e um processo de Markov de primeira ordem. Esta metodologia foi aplicada a um conjunto com futuras interrupções

programadas, com o objetivo de calcular o fluxo de potência para avaliar o nível de segurança de um sistema de energia elétrica.

Em Marinescu *et al.* (2013), os autores examinaram várias abordagens para o problema da previsão de carga por barramento, com vistas a obter a demanda dia e semana à frente, de várias casas que recebem energia elétrica por um transformador residencial comum. Os modelos analisados foram: redes neurais artificiais, lógica difusa, auto-regressão, média móvel auto-regressiva, média móvel integrada auto-regressiva e redes neurais *wavelet*. Para avaliação dessas abordagens, foram utilizados dados históricos de carga com informações meteorológicas registradas por um medidor inteligente entre 2009 e 2010 na Irlanda. Dois cenários diferentes foram estudados, um com 90 casas e outro com 230 casas. Neste estudo as redes neurais proporcionaram um erro médio inferior a 4% nos dois cenários propostos, se igualando com algumas metodologias (redes neurais *wavelet*) e superando outras (neuro-*fuzzy*) em termos de resultados.

Panapakidis (2016) propôs um modelo de previsão de carga multinodal de curto prazo, por meio de um processo que ocorre em duas etapas, na primeira, os dados são aplicados em uma rede neural modificada e, em um segundo momento, para melhorar a precisão das previsões o autor utiliza o perfil das cargas resultantes da rede neural, para formular dois novos modelos híbridos de previsão que compreendem na combinação da rede neural com um algoritmo de agrupamento.

O trabalho de Amjady (2007), propõe um método híbrido para a previsão de carga multinodal a curto prazo de sistemas de energia. O modelo é composto por um estimador de estado que auxilia na previsão e por uma rede neural do tipo perceptron multicamadas. Nesta metodologia, o estimador de estado prevê as cargas horárias de cada barramento por meio de seus dados históricos e na sequência, suas entradas e saídas são fornecidos ao modelo neural.

Na referência de Salgado, Ohishi e Ballini (2011), foi proposto um método, por redes neurais artificiais, para realizar a previsão de demanda de carga por barramentos. Uma RNA do tipo perceptron multicamadas foi aplicada em duas condições: Na primeira, a previsão é realizada individualmente e na outra, os barramentos com perfil semelhante de carga diária foram agrupados, formando diferentes *clusters*.

Na publicação de Singh, Vaibhav e Chaturvedi (2012), os autores propuseram um modelo de previsão multinodal, para prever a demanda horária de uma subestação de energia elétrica. Para isso, dois métodos foram analisados sendo: rede neural artificial e rede neural generalizada. Os modelos foram treinados e testados usando dados reais de tempo e carga

horária obtidos da subestação e os resultados foram comparados para demandas de eletricidade de três meses.

Os autores Altran (2010), Nose-Filho (2011), Abreu (2012), Antunes (2013) e Amorim (2019) propuseram diferentes modelos para realizar a previsão de carga multinodal via redes neurais, com o objetivo de obter previsões a curto prazo. As metodologias desenvolvidas foram aplicadas a dados históricos de cargas elétricas de subestações de um sistema de energia da Nova Zelândia, visando obter dados 24 horas à frente.

Na publicação Kenaya e Cheok, (2008a), foi proposta uma rede neural do tipo ARTMAP, que utiliza a distância euclidiana nos padrões de entrada de um sistema de rastreamento de alvos em movimento. Os autores salientaram a importância deste modelo, devido a grande capacidade que este possui de imitar certos sistemas para fornecer um desempenho próximo do original, concluindo assim, a grande utilidade e aplicabilidade desta rede.

Em Yaakob, Lim e Jain (2010), foi apresentado um modelo de rede neural do tipo ARTMAP com limiar de qualidade euclidiana, aplicada à classificação de padrões. O objetivo desta pesquisa foi utilizar o referido modelo para tentar superar os efeitos das sequências de dados de treinamento na rede ARTMAP *Fuzzy* e, ao mesmo tempo, melhorar seu desempenho na classificação. Para verificar a eficácia desta arquitetura, vários conjuntos de dados artificiais e de dados médicos foram utilizados. Neste estudo, a rede ARTMAP Euclidiana apresentou bons resultados, com desempenho robusto no que diz respeito aos efeitos de ordens ou sequências de dados de treinamento na classificação de padrões.

Barros *et al.* (2015), visando detectar e classificar disfunções de tensão em sistemas de distribuição de energia, utilizou a rede neural ARTMAP Euclidiana modificada com treinamento continuado. Como resultado, constatou-se um método de diagnóstico bastante satisfatório, que foi capaz de identificar todas as anomalias do sistema, além disso, a rede neural proposta apresentou características vantajosas em relação a outros modelos neurais, por permitir o constante melhoramento das classes existentes.

O trabalho de Moreno (2010) apresentou a rede neural ART-ARTMAP *Fuzzy* Euclidiana modificada com treinamento continuado, esta metodologia foi aplicada ao problema de análise da estabilidade transitória de sistemas de energia elétrica multimáquinas. Os resultados demonstraram um tempo de processamento bastante reduzido e excelente precisão nas previsões.

Marchiori *et al.* (2011) utilizou uma rede neural do tipo ARTMAP Euclidiana no desenvolvimento de um método que analisa a estabilidade transitória de primeira oscilação de

sistemas de energia elétrica. Neste estudo, concluiu-se que a rede neural Euclidiana proporciona previsões com grande rapidez e precisão, com capacidade de aprender mantendo as informações anteriores, promovendo um constante aperfeiçoamento das soluções.

Em Gomes (2017), a rede neural artificial ARTMAP Euclidiana é utilizada na problemática da previsão de carga global a curto prazo. Os resultados demonstraram que esta arquitetura apresenta maior precisão quando comparados às soluções obtidas com o modelo neural ARTMAP *Fuzzy*, e também, por meio dos erros percentuais médios (MAPE) obtidos, foi possível constatar um melhor desempenho em termos de rapidez e precisão, se comparados com outros resultados disponíveis na literatura especializada, obtidos por diferentes arquiteturas neurais e híbridas.

Os estudos apresentados nesta seção evidenciam a quantidade reduzida de trabalhos na literatura especializada que abordam o contexto de previsão multinodal, haja vista que, a grande maioria trata a previsão envolvendo o somatório de todas as cargas, isto é, a previsão global. Além disso, no que se refere à aplicação da rede neural ARTMAP Euclidiana para realizar previsões de cargas elétricas, é notória a limitada quantidade de pesquisas que aplicam a referida metodologia nesta problemática, sobretudo no que se refere à previsão multinodal. Entretanto, a maioria desses estudos foram fontes valorosas de conhecimento, pois proveram bases para a realização deste trabalho.

3 PREVISÃO DE CARGAS ELÉTRICAS

Os modelos de previsão são vastamente utilizados em diversas áreas do conhecimento, sendo uma importante ferramenta em diferentes aplicações, como: previsão de ações e índices de bolsas de valores, monitoramento de propagação de doenças, demanda de negócios, previsões meteorológicas, entre outras (KUSTER; REZGUI; MOURSHED, 2017). Igualmente, as predições atuam de forma crucial no segmento dos Sistemas Elétricos de Potência (SEP), desempenhando um importante papel por mais de 100 anos neste mercado (HONG, 2014).

As pesquisas na área da previsão de carga, no último século, concentraram seus esforços principalmente na obtenção da demanda de cargas elétricas pontuais. Já na última década, fatores como o aumento da competitividade no mercado energético, envelhecimento das edificações e as exigências de integração renovável, trouxeram uma nova perspectiva para esta abordagem, tornando-a cada vez mais necessária para o planejamento e operação dos sistemas elétricos de potência (HONG; FAN, 2016).

Desta forma, a previsão de carga precisa aplicada ao setor energético é de essencial importância para evitar possíveis problemas operacionais, como blecautes no caso da subestimação da demanda ou desperdício de energia em ocorrência da superestimação da mesma. Além disso, as predições exercem um papel de diferencial estratégico na compra e venda de eletricidade, afetando de forma direta o sistema tarifário de energia (SFETSOS, 2003; NASSIF, 2016).


3.1 PREVISÃO DE CARGA MULTINODAL

Os sistemas elétricos de potência (SEPs) são modelos dinâmicos e em sua maioria de grande porte, cuja função é converter para a forma elétrica os mais diversos recursos disponíveis na natureza, como: água (hidrelétrica), vento (eólica), sol (solar), etc. Após transformar esses meios em energia, esse sistema deverá ser capaz de transmitir a eletricidade gerada para os consumidores nas áreas mais abrangentes de forma limpa, segura e eficiente. Para que isso seja possível, os SEPs dispõem de uma série de componentes essenciais ao seu funcionamento como estações geradoras, redes de transmissão e distribuição, transformadores, dispositivos, entre outros elementos (KUNDUR, 1994).

Desta forma, os SEPs são subdivididos em três sistemas diferentes, sendo: sistema de geração, sistema de transmissão e sistema de distribuição. O primeiro dá início ao processo,

convertendo a energia primária (água, gás, vapor, etc.) em eletricidade, o segundo por sua vez, transporta a energia gerada até os centros consumidores, por fim, o terceiro é responsável por receber a energia da rede de transmissão e distribuí-la para os centros de consumo residenciais, comerciais e industriais (KUNDUR, 1994). A Figura 1 ilustra a estrutura básica de um sistema elétrico de potência.

Figura 1 – Fluxograma de um sistema elétrico de potência.



Fonte: Elaborado pela própria autora.

Apesar de possuírem atividades diferentes, os subsistemas que compõem os SEPs estão interligados de forma que, a falha em um desses processos ocasionará na interrupção da provisão energética e prejuízos ao sistema elétrico como um todo, desta forma, para o êxito das atividades nos SEPs esses elementos devem atuar de forma sequencial e sincronizada (AMORIM, 2019).

Os sistemas de transmissão (STs) são constituídos por diversos componentes, como transformadores, linhas de transmissão, dispositivos de controle, entre outros elementos que compõe a rede elétrica. A partir da disposição desses componentes, pode-se obter um modelo matemático desse sistema por meio da aplicação da teoria de grafo (sistema gráfico de fluxo), desta forma, os arcos simbolizam os elementos do sistema (transformadores, linhas de transmissão, etc.) e os “nós”, também denominados de barramento, configura o vínculo entre esses elementos. Cada consumidor da rede elétrica está conectado a um barramento do sistema de transmissão, cuja demanda de carga a ser suprida por este nó é definida pela soma de todos os seus consumidores. Neste sentido, é importante que a companhia fornecedora de

energia elétrica avalie as operações do sistema de transmissão com base na previsão da demanda energética em cada barramento, para que assim o sistema elétrico opere de forma segura, confiável e econômica (SULLIVAN, 1977).

Diante do exposto, nota-se a necessidade de conhecer a demanda de carga a ser suprida por cada barramento do sistema. Essa distribuição pode ser provida por meio da carga global, que compreende a soma de todas as cargas individuais do sistema, isto é, de todos os barramentos. Basicamente, esse processo de divisão da carga global pode ser feito de duas maneiras: na primeira, realiza-se a distribuição de forma proporcional entre as barras, aplicando um fator de participação constante ou outro método heurístico, como média referente ao período no qual se pretende determinar. Os resultados deste método apresenta um nível considerável de imprecisão. Já a segunda forma, compreende na aplicação da previsão multimodal, cuja abordagem considera todos os nós (barramentos) do sistema elétrico (AMORIM, 2019).

Assim, a previsão de carga multimodal ou por barramento, sugere uma abordagem cuja demanda deixa de ser compreendida apenas pela totalidade das cargas a serem fornecidas, isto é, a previsão deixa de operar somente com a carga total (global) do sistema. Na abordagem multinodal, propõe-se conhecer a distribuição das cargas entre os diversos pontos da rede elétrica, ou seja, vários barramentos do sistema elétrico (subestações, transformadores, etc.) são considerados (PYNE, 1974; PARK; SHARKAWI; MARK II, 1991).

A previsão de carga de forma global pode ser vantajosa nas atividades estratégicas do SEPs, como despacho da energia gerada, compra de eletricidade, etc. Contudo, o mesmo não se aplica às atividades de operação, pois neste caso há a necessidade de conhecer o sistema de transmissão de forma mais aprofundada, isto é, de forma multinodal. Ressalta-se, que a previsão por barramento, constituindo-se de um maior volume de informação com natureza complexa, contudo, para garantir a viabilidade dessa abordagem e seus resultados, a previsão multinodal não deverá dispor de um tempo de processamento computacional muito superior à previsão global (WU; YUAN; ZHU, 2003; AMORIM, 2019).

Isso posto, visando produzir resultados precisos e confiáveis dispondo do menor tempo de processamento possível para o problema da previsão de cargas elétricas, nesta pesquisa foram empregadas duas metodologias, uma que prevê a demanda em cada barramento e a outra que utiliza as cargas a serem atendidas em sua totalidade (global). Assim, neste estudo será abordada tanto a previsão global (total) quanto à previsão multinodal.

3.2 CLASSIFICAÇÃO DA PREVISÃO DE CARGAS ELÉTRICAS

As atividades em um sistema elétrico de potência podem ser executas em diferentes períodos de tempo. A tomada de decisão com relação às operações diárias, por exemplo, podem ocorrer de forma imediata ou até em algumas horas. Já o planejamento de expansão, que envolve o estudo de retorno de capital, análise de receita, etc., pode se concretizar em meses ou até anos (PARLOS *et al.*, 1996). Em razão disso, existe uma classificação da previsão conforme o intervalo de tempo em que a carga é prevista (minutos, horas, dias, semanas, etc.). Assim, em uma escala temporal, as previsões podem ser classificadas da seguinte forma (AL-KANDARI *et al.*, 2004; LOPES, 2005; MURTO, 1998):

- *Previsão de carga a curtíssimo prazo:* dá-se em alguns segundos, com intervalo máximo de 15 minutos. Fornece informações úteis para a preparação, organização e estruturação de produção *on-line* e controle.
- *Previsão de carga a curto prazo:* realiza-se de meia em meia hora ou horária atingindo o espaço de um dia até uma semana. Provê dados essenciais para o planejamento e operação diário dos SEPs.
- *Previsão de carga a médio prazo:* contempla o período de algumas semanas a até alguns anos. Propicia informações úteis para a manutenção e coordenação das unidades geradoras.
- *Previsão de carga a longo prazo:* utiliza dados contendo as predisposições de consumo de um longo período de tempo e abrange um intervalo de 10 a 20 anos. Viabiliza dados úteis ao planejamento de expansão.

Como já mencionado neste trabalho, a previsão de carga desempenha um papel fundamental para que o sistema de energia opere de forma econômica com segurança e confiabilidade. Deste modo, a previsão de carga de curto prazo tem se tornando uma importante ferramenta para esta problemática, pois desempenha um papel crucial em termos de controle, segurança, operação e programação dos Sistemas Elétricos de Potência (ZHENG; YUAN; CHEN, 2017). Assim, nesta pesquisa optou-se por trabalhar com a previsão de carga de curto prazo com um horizonte preditivo 24 horas à frente, deste modo, esta escala temporal será enfatizada neste trabalho.

3.3 FATORES QUE INFLUENCIAM A CARGA ELÉTRICA

Apesar de essencial para os sistemas elétricos de potência, a previsão imprecisa pode acarretar em um encarecimento do custo operativo destes sistemas, ocasionando grandes prejuízos à companhia energética. Desta forma, os resultados das predições devem ser obtidos com rapidez, precisão e confiabilidade. Contudo, vários elementos exógenos exercem influência sobre as cargas, propiciando grande não linearidade nas séries de demanda e elementos complexos que dificultam a exatidão nas previsões (BUNN; FARMER, 1985).

Os barramentos da rede elétrica são conectados a diferentes classes de consumidores, sendo: residenciais, comerciais e industriais. Por este ângulo, quando se aproxima da carga individual em nível de consumidor, existe uma diminuição da previsibilidade, posto que, cada classe consumidora apresenta padrões de consumo diferentes (ANTUNES, 2013).

Os fatores que influenciam as cargas residenciais são os mais difíceis de determinar, pois essa classe é composta por uma diversidade de indivíduos, que por sua vez, apresentam padrões distintos de consumo. Já a classe industrial, que representa grande parte da demanda energética é considerada previsível, haja vista que, o consumo resulta da intensidade na produção das manufaturas. Entretanto, eventos inesperados como acidentes, paralizações, entre outros fatos que podem ocasionar perturbações na carga elétrica e consequentemente, maior dificuldade nas previsões (LOPES, 2005).

Além do padrão de consumo, diversos fatores exógenos dificultam a previsão dos níveis de demanda do sistema, pois exercem influência no comportamento das cargas elétricas (GROSS; GALIANA, 1987). O Quadro 1 demonstra esses fatores, bem como, os tipos de previsões que essas variáveis influenciam.

Quadro 1 - Fatores exógenos que influenciam a carga elétrica.

Fatores de Influência	Previsão que Influencia	Descrição
Econômicos e Demográficos	Médio e Longo Prazo	▪ Área demográfica (industrial, rural, residencial), ▪ Expansão da atividade manufatureira, ▪ Mudanças na agricultura, ▪ Tendências econômicas, etc.
Climáticos	Curto, Médio e Longo Prazo	▪ Condições meteorológicas: velocidade do vento, temperatura, chuva, umidade relativa do ar, etc.
Temporais	Curto e Médio Prazo	▪ Efeitos sazonais: férias, feriados, natal, etc. ▪ Efeitos cíclicos: sábados, domingos, etc.

Esporádicos	Curto e Médio Prazo	▪ Eventos esportivos (copa do mundo, olimpíadas), ▪ Paralisações, etc.
-------------	---------------------	---

Fonte: Elaborado pela própria autora.

Como pode ser observado no Quadro 1, os fatores climáticas, temporais e esporádicas exercem um papel de grande influência principalmente nas previsões de curto e médio prazo, haja vista que, esses elementos exógenos podem se modificar em um breve período de tempo. As variáveis climáticas são fenômenos naturais, cujo elemento de maior influência está na temperatura, tendo em conta que com a elevação ou queda deste fator, é previsível um aumento significativo no uso de aparelhos condicionadores de ar, aquecedores elétricos, refrigeradores, climatizadores, etc. (SWARUP; SATISH, 2002). As variáveis temporais, por sua vez, são determinadas por um grupo de elementos como hora, dia da semana, mês, etc., cujo comportamento é cíclico ou sazonal. São definidos como cíclicos os fatores temporais que ocorrem com periodicidade definida (dias da semana), já os sazonais, influenciam a variação das cargas em circunstância de acontecimentos diversos em determinados períodos atípicos do ano. Por fim, as variáveis esporádicas são eventualidades aleatórias que causam perturbações na carga elétrica e que não podem ser definidas pelos outros fatores de influência mencionados nesta seção (MURTO, 1998).

No que diz respeito à previsão de carga a curto prazo via redes neurais, metodologia proposta neste trabalho, essas variáveis exercem forte influência negativa na capacidade de aprendizagem e generalização dos modelos neurais, haja vista, as fortes perturbações que causam nas cargas elétricas. Contudo, o conhecimento dados históricos desses fatores de influência como dia da semana, hora, temperatura etc., representam o comportamento das cargas e podem auxiliar na previsão precisa. Na proposta deste trabalho, o modelo previsor a curto prazo utiliza como entrada da rede neural além de dados históricos de cargas, dados exógenos temporais cíclicos (dia da semana) e sazonais (hora).

3.4 TÉCNICAS DE PREVISÃO DE CARGA ELÉTRICA

Visando obter resultados expressivos nas previsões, diversas técnicas surgiram na literatura nas últimas décadas, sendo categorizadas em dois grupos (GROSS; GALIANA, 1987):

- *Técnicas Estáticas*: a carga é apresentada na forma de uma série temporal discreta, cuja composição é formada por valores previstos de forma horária, no decorrer de um determinado período.
- *Técnicas Dinâmicas*: a carga é caracterizada por apresentar além da função de tempo do dia, exhibe também os valores históricos das entradas, ou seja, os comportamentos passados das cargas.

Historicamente as técnicas com abordagens estatísticas foram amplamente utilizadas pelos pesquisadores na problemática da previsão de cargas elétricas. Após chegada dos *softwares* estatísticos e o surgimento da inteligência artificial (IA), novos métodos de previsão foram desenvolvidos trazendo uma nova perspectiva para o adiantamento da demanda futura. Desta forma, os métodos preditivos são categorizados em dois tipos: métodos estatísticos tradicionais e métodos baseados em IA (SHAHIDEHPOUR; YAMIN; LI, 2003; HONG; FAN, 2016).

Os métodos estatísticos aplicam combinações matemáticas aos dados históricos das cargas, cujas entradas são obtidas por meio da análise da similitude entre as variáveis de entrada e saída. Esses métodos de previsão incluem: regressão linear ou múltipla (MURTO, 1998; SFETSOS, 2003), filtro de Kalman (MOGHRAM; RAHMAN, 1989; MURTO, 1998), alisamento exponencial (MOGHRAM; RAHMAN, 1989), espaço de estado e série temporal de Box-Jenkins (O' DONOVAN, 1983).

Já os Sistemas Especialistas são algoritmos baseados em Inteligência Artificial que buscam simular o raciocínio humano, basicamente neste método, o conhecimento é construído por meio de várias regras de execução (ZADEH, 1965). Os exemplos incluem sistemas *fuzzy*, programação evolutiva, redes neurais artificiais (RNAs) e etc. (SHAHIDEHPOUR; YAMIN; LI, 2003).


Damborg *et al.* (1990) afirma que os modelos neurais possuem a capacidade potencial de superar a dependência de uma forma funcional de um método de previsão. Desta forma, diversas pesquisas têm evidenciado que os modelos de redes neurais são superiores as abordagens clássicas, no que tange à precisão dos resultados (JOVANOVIĆ; SRETENOVIĆ; ŽIVKOVIĆ, 2015; CHAE *et al.*, 2016; DEB *et al.*, 2015). Dentro desta perspectiva, visando obter previsões com rapidez, precisão e confiabilidade, esta pesquisa propõe uma metodologia cujo método preditivo adotado é composto por redes neurais artificiais.

3.4.1 Redes Neurais Artificiais

As redes neurais artificiais (RNAs) tiveram origem a partir de uma inspiração biológica, que viabilizou a criação de um modelo pioneiro de neurônio artificial elaborado por McCulloch e Pitts (McCULLOCH; PITTS, 1943) em 1943, que unia através de cálculos lógicos, as concepções da neurobiologia e da lógica matemática. (HAYKIN, 2008).

Os neurônios biológicos são células constituídas por três partes que atuam de forma relacionada, sendo: corpo celular ou soma, dendritos e axônio. Os dendritos são responsáveis por receber os estímulos de outros neurônios e os enviar até o corpo celular que, por sua vez, transforma as informações recebidas em novos impulsos elétricos, que são propagados para outras unidades celulares através do axônio. As conexões que ocorrem entre o axônio de um neurônio e o dendrito de outra unidade celular, são realizadas por meio de impulsos nervosos chamados de sinapses, formando assim, uma série de interconexões. Desta forma, o cérebro humano é constituído por uma rede neural, composta por diversas unidades que possuem a capacidade de processar e transmitir informações por meio da geração e propagação de sinais elétricos (ANDERSON, 1995). A Figura 2 ilustra o modelo de um neurônio biológico com suas partes e conexões.

Figura 2 – Desenho de um neurônio biológico e suas conexões.




Fonte: Adaptação (HAYKIN, 2008).

A presença de manifestações elétricas nos neurônios biológicos foi descoberta no século XIX por meio de aparelhos galvanômetros. Duas décadas depois, após diversas pesquisas, o neurônio biológico passou a ser entendido como um dispositivo computacional constituído por diversas entradas e uma saída. Desta maneira, as entradas são os impulsos elétricos que ocorrem através das conexões sinápticas e a saída é um novo pulso obtido por

meio do processamento das entradas, emitido pelo neurônio receptor dos estímulos (KOVÁCS, 1996).

O neurônio artificial apresentado por McCulloch e Pitts (Figura 3) é formulado com estrutura e funcionamento similar ao neurônio biológico, possibilitando uma ou mais entradas e um sinal de saída. As sinapses são representadas pelos pesos, que compreende em um indicador do grau de relevância que uma entrada específica apresenta em referência ao neurônio correspondente. Desta forma, as entradas são multiplicadas por esse indicador (pesos) e a saída é obtida por meio da soma desses resultados, gerando um sinal que deverá estar em conformidade com uma função interna de ativação do neurônio (SHERRY, 1996).


Figura 3- Esquema do neurônio artificial de McCulloch e Pitts.



Fonte: Adaptação (LOPES, 2005).

A Figura 4 ilustra o modelo clássico de um neurônio artificial. As informações fornecidas por outros neurônios formam um conjunto de entradas ($x_1 x_2 \dots x_n$), sendo que cada entrada está vinculada a um peso w_n que atua como um indicador do grau de importância de x_n , desta forma, as sinapses ocorrem por meio da multiplicação entre as entradas e o respectivo peso ($x_1 w_1 x_2 w_2 \dots x_n w_n$). Por fim, os sinais resultantes são aplicados a um bloco somatório Σ (corpo celular), se o valor obtido pela soma ponderada das entradas ultrapassar o valor de w_0 (peso bias), a unidade celular se torna ativa e emite um sinal de saída (valor 1 na saída binária y), de outro modo, a unidade não é ativada (valor 0 na saída binária y). O peso bias é estipulado para controlar o nível de saída do neurônio, este pondera uma entrada arbitrária $x_0 = +1$ (WASSERMAN, 1989; STORB; WAZLAWICK, 1999).


Figura 4 – Esquema de um neurônio artificial.



Fonte: Adaptação (LOPES, 2005).

A ativação de um neurônio artificial é determinada por meio da função de ativação, existem diferentes tipos de funções que podem gerar a saída do neurônio. A Figura 5 ilustra alguns desses modelos: (1) função linear, que fornece uma saída linear contínua; (2) função relé, que fornece saídas binárias; (3) função sigmoidal que emite uma saída não-linear contínua (FINE, 1999; STORB; WAZLAWICK, 1999).

Figura 5- Quadro de exemplos de funções de ativação.




Fonte: Adaptação (MARCHIORI, 2006).

As RNAs podem ser entendidas como um sistema computacional estruturado para simular a atividade neural humana. Trata-se de um conjunto de elementos de processamento relativamente simples interligados entre si, de modo que a composição estrutural entre essas unidades locais define a inteligência da rede como um todo. Quando um dos neurônios dessa estrutura recebe um pulso de entrada, este elemento processa os sinais recebidos e propaga um estímulo novo como saída, que por sua vez, se torna entrada para outros neurônios da rede. Esse paralelismo entre as unidades que compõem as arquiteturas neurais é estruturado em camadas, sendo: camada de entrada, camada intermediária e camada de saída.

Assim, de acordo com o método de propagação da informação recebida, existe uma categorização segundo a topologia dos neurônios (Figura 6) (KROSE; SMAGT, 1996):

- *Redes Neurais Recorrentes (feedback)*: são redes realimentadas, isto é, as ligações entre os neurônios não possuem restrições. Esses modelos neurais desenvolvem uma memória nos elementos internos, a rede auto-associativa de Hopfield (HOPFIELD, 1982) representa essa topologia.
- *Redes Neurais Não Recorrentes (feedforward)*: são modelos neurais cuja propagação da informação é para frente e unidirecional, isto é, os neurônios desta rede recebem as informações somente de camadas anteriores. São exemplos às redes perceptron (ROSENBLATT, 1958) e perceptron multicamada (RUMELHART; HINTON; WILLIAMS, 1986).

Figura 6- Esquema com as principais topologias das RNAs.



Fonte: (MARCHIORI, 2006).

Todo o potencial das RNAs está na capacidade que estas possuem de adquirir conhecimentos para executar diferentes tarefas. Para isso, a rede precisa ser treinada de forma que produza os resultados almejados a partir de um conjunto de padrões de entrada. A fase de treinamento dos modelos neurais consiste em um processo de ajuste dos pesos conforme as entradas apresentadas à rede, isso é, procura-se adaptar de maneira ótima os graus de liberdade que o modelo possui para resolver determinada atividade proposta. Existe uma diversidade de algoritmos utilizados para ajustar os pesos no decorrer da fase de treinamento, assim de acordo com o paradigma de aprendizagem o treinamento pode ser classificado como (FAUSETT, 1994; KROSE; SMAGT, 1996):

- *Treinamento Supervisionado*: é realizado por meio da associação dos conjuntos de entrada e saída. Neste treinamento, existe a necessidade de um agente externo supervisor, que adquire o conhecimento sobre a rede por meio do mapeamento dos padrões recebidos. Esse agente atua no processo de aprendizagem avaliando e informando à rede neural a respeito de seu desempenho. São exemplos as redes neurais ARTMAP e a ARTMAP Fuzzy (CARPENTER; GROSSBERG, 1992).
- *Treinamento Não-Supervisionado*: trata-se de um modelo autônomo e por aglomeração (“*clustering*”), isto é, a rede tem a responsabilidade de encontrar atributos estatísticos sobre o seu desempenho por meio do desenvolvimento de uma representação própria dos conjuntos de entrada e saída. As redes Hopfield (HOPFIELD, 1982), Kohonen (KOHONEN, 1990), ART (GROSSBERG, 1976) e ART Fuzzy (CARPENTER; GROSSBERG; ROSEN, 1991) são exemplos desse tipo de treinamento.
- *Treinamento Competitivo*: neste modelo a rede possui vários elementos de saída que competem entre si para fornecer a saída desejada. Assim, apenas o neurônio vencedor poderá emitir um sinal de ativação, ao tempo que, os demais permanecem com ativação nula. A rede *counterpropagation* representa esse tipo de treinamento (STORB; WAZLAWICK, 1999).
- *Treinamento Híbrido*: ocorre por meio da combinação alternada entre os treinamentos supervisionado e não-supervisionado.

A estrutura das RNAs possibilita diversas características vantajosas e de grande importância para solucionar problemas complexos, como: capacidade de aprendizado e generalização do conhecimento; processamento paralelo, proporcionando maior agilidade na

realização de tarefas complexas; não linearidade, sendo uma opção analítica, uma vez que os procedimentos convencionais são limitados; robustez, pois são capazes de lidar com dados ruidosos ou incompletos; e flexibilidade, já que podem ser aplicadas em diversas áreas do conhecimento (HAYKIN, 2008; STORB; WAZLAWICK, 1999).


4 TEORIA DA RESSONÂNCIA ADAPTATIVA

A descoberta das redes neurais artificiais deu origem a diversos modelos cerebrais para a execução de algoritmos específicos, fomentando diversas pesquisas com a finalidade de obter maior eficiência das RNAs. No ano de 1976, Grossberg apresentou novo conceito de rede neural, denominado teoria da ressonância adaptativa (ART) (GROSSBERG, 1976). Esta metodologia é composta por dois subsistemas: o primeiro, responsável pelo reconhecimento e o segundo, por sua vez exerce uma ação generativa. Desta forma a atividade neural é estendida através do que foi chamado de “ressonância adaptativa” (HAYKIN, 2008).

Essa teoria teve origem na necessidade de resolver o dilema da plasticidade e estabilidade. A plasticidade está na capacidade que a rede possui de manter o conhecimento adquirido anteriormente e ao mesmo tempo armazenar novas informações. Quanto à estabilidade, está se refere à garantia de que todos os padrões fornecidos a rede neural serão agrupados em categorias (LOPES, 2005).

A partir da primeira arquitetura ART foram desenvolvidos vários modelos visando o melhoramento da capacidade de generalização desses sistemas e conseqüentemente, melhorar o desempenho na solução de problemas. Assim, a teoria da ressonância adaptativa deu origem a diversos modelos neurais, conhecidos como família ART (Figura 7).

Figura 7- Esquema simplificado da família ART.



Fonte: Adaptação (SANTOS JÚNIOR, 2017).

Arquiteturas que possuem o treinamento do tipo não supervisionado:

- *Rede Neural ART1*: trata-se de um modelo que admite apenas padrões binários e é composto por várias equações que visam garantir a estabilidade e a plasticidade (CARPENTER; GROSSBERG, 1988).
- *Rede Neural ART2*: essa arquitetura apresenta a habilidade de admitir padrões de entrada binários e analógicos, além disso, dispõe de um procedimento de normalização de dados proporcionando maior robustez a esta rede neural (CARPENTER; GROSSBERG, 1988).
- *Rede Neural ART Fuzzy*: esse modelo que possui a capacidade de categorizar padrões entre 0 e 1, além disso, os cálculos desta arquitetura são baseados em lógica nebulosa (CARPENTER, GROSSBERG, ROSEN, 1991).
- *Rede Neural ART Euclidiana*: trata-se de uma arquitetura que classifica os padrões de entrada de acordo com um algoritmo que calcula a distância euclidiana e decide se uma nova classe deve ser inserida em um *cluster* já existente ou se a considera como uma nova categoria (CARPENTER, ROSS, 1995).

Arquiteturas que possuem o treinamento do tipo supervisionado:

- *Rede Neural ARTMAP*: esta arquitetura é formada por dois módulos ART que se relacionam por meio de um terceiro bloco denominado inter-ART. O modelo ARTMAP reconhece tanto padrões de entrada binários, quanto analógicos (CARPENTER; GROSSBERG; REYNOLDS, 1991).
- *Rede Neural ARTMAP Fuzzy*: este modelo apresenta uma arquitetura semelhante a RNA ARTMAP, contudo, é composta por dois módulos ART *Fuzzy* (CARPENTER *et al.*, 1992).
- *Rede Neural ARTMAP Euclidiana*: a organização dessa rede é similar à arquitetura ARTMAP, porém é composta por dois módulos da RNA ART Euclidiana (CARPENTER, ROSS, 1995).


A família ART é bastante extensa composta por uma diversidade de modelos que se fundamentam na teoria da ressonância adaptativa, contudo, essa pesquisa se limita ao estudo e aplicação da rede neural ARTMAP Euclidiana, objeto de estudo da metodologia proposta neste trabalho.

4.1 REDE NEURAL ART

Com intuito de garantir a plasticidade-estabilidade a RNA ART (*Adaptive Resonance Theory*) cria agrupamentos com base na similaridade entre as entradas fornecidas à rede, através de um critério racional de alocação de padrões. Deste modo, a arquitetura ART é composta por dois subsistemas (Figura 8):

- *Subsistema de Atenção*: composto pelas camadas de neurônios F_0 , F_1 e F_2 , das quais: F_0 representa o vetor de entrada atual (A), F_1 realiza o processamento dos dados de entrada (comparação) e F_2 forma as categorias de reconhecimento agrupando os padrões de treinamento. Os pesos w_j associados às conexões entre F_1 e F_2 são responsáveis pelo armazenamento de longo prazo (*long - term memory*) das informações (KEYVAN *et al.*, 1999; CARPENTER; GROSSBERG, 1992).
- *Subsistema de Orientação*: é regido pelo parâmetro de vigilância ρ ($\rho \in [0,1]$) que determina o *reset* e a ressonância no processo de classificação de categorias, isto é, define se uma categoria indicada pelo subsistema de atenção deve ser aceita (ressonância) ou se o referido sistema deve ser orientado a buscar por uma nova categoria (*reset*) (GOPAL *et al.*, 1999; KEYVAN *et al.*, 1999).

Figura 8- Esquema da arquitetura da rede neural ART.



Fonte: Adaptação (LOPES, 2005).


As categorias criadas pelo algoritmo da rede neural ART podem ser ilustradas por meio de uma representação geométrica em forma de hiper-retângulos. Nesta representação, são determinados valores entre mínimo (Min) e máximo (Max.) (CARPENTER, GROSSBERG, 1992). A Figura 9 demonstra geometricamente as classes de uma RNA ART, na qual, os vetores $u = [u_1 \ u_2]$ e $v = [v_1 \ v_2]$ estão relacionados aos operadores lógicos $\wedge$ (AND) e $\vee$ (OR), da seguinte forma:

$$(u \wedge v)_1 = \min(u_1, v_1), (u \wedge v)_2 = \min(u_2, v_2)$$

$$(u \vee v)_1 = \max(u_1, v_1), (u \vee v)_2 = \max(u_2, v_2)$$

Sendo: u e v vetores gerados a partir do vetor peso $w_j = [u_j \ v_j]$, codificado em complemento $w_j = [u_j \ v_j^c]$ (CARPENTER, GROSSBERG, 1992).

Figura 9 - Representação geométrica em hiper-retângulos.



Fonte: (LOPES, 2005).

Os parâmetros que envolvem a RNA ART exercem um papel fundamental no desenvolvimento da aprendizagem, logo, são de extrema importância durante a fase de treinamento da rede. Dentre eles destacam-se:

- *Parâmetro de Escolha* ($\alpha > 0$): é responsável por controlar a procura em meio aos elementos da camada de reconhecimento (F_2), isto é, caso um padrão de entrada se adeque a diferentes hiper-retângulos, o parâmetro de escolha garante que o menor hiper-retângulo seja selecionado (CARPENTER; GROSSBERG, 1987; KEYVAN et al., 1999).

- *Taxa de Treinamento* ($\beta \in [0,1]$): o valor de β atua como um indicador da taxa de treinamento. Ou seja, quanto mais próximo de 0 (zero) mais lento será o treinamento da rede, no entanto, o valor de β próximo de 1 (um) promove um treinamento ágil (CARPENTER; GROSSBERG, 1987).
- *Parâmetro de Vigilância* ($\rho \in [0,1]$): o valor de ρ determina o grau de disparidade permitido entre os elementos de cada categoria. Ou seja, quanto mais próximo de zero menor a similaridade entre os padrões agrupados na mesma classe, gerando um número reduzido de categorias. Por outro lado, se o valor de ρ estiver próximo de 1 maior será o grau de semelhança entre os elementos, levando a criação de um número maior de classes (GOPAL et al., 1999; KEYVAN et al., 1999).

4.2.1 REDE NEURAL ARTMAP

Fundamentada na teoria da ressonância adaptativa (ART), o modelo neural ARTMAP foi criado em 1991 visando trazer um treinamento supervisionado e auto-organizável garantindo a estabilidade e a plasticidade (LIM; HARRISON, 1997). A arquitetura desta rede é composta por dois módulos ART, intitulados ART_a e ART_b , e também, por um terceiro módulo denominado Inter-ART. O par de módulos ART possui a função de organizar os padrões de entrada em classes de reconhecimento. Já o bloco Inter-ART, este por sua vez, realiza um mapeamento por meio da associação das classes identificadas em ART_a e ART_b , interconectando esses dois módulos (CARPENTER; GROSSBERG; REYNOLDS, 1991).


No modelo ARTMAP, o módulo ART_a recebe os padrões de entrada e o módulo ART_b possui a saída pretendida correlata. Quando ocorre um prognóstico errado por parte da rede, ρ_a sofre um acréscimo mínimo até que o erro no módulo ART_b seja corrigido. Esse procedimento é executado pelo mecanismo de *match tracking* ou inter-ART que atua como um autorregulador da rede maximizando a generalização e assim, diminuindo o erro. Desta forma, procura-se por uma nova classe para ser associada à entrada atual no módulo ART_a , essa busca é realizada até que um prognóstico correto seja encontrado e exista combinação com a categoria identificada ao módulo ART_b (CARPENTER; GROSSBERG; REYNOLDS, 1991).

A conexão associativa das categorias de reconhecimento nos módulos ART_a e ART_b , é verificada por meio do inter-ART que obtém as entradas dos dois blocos supracitados. Se houver combinação entre as duas entradas, a rede irá obter o aprendizado por meio da

modificação dos exemplares das categorias identificadas em ART_a e ART_b , considerando uma regra de treinamento. Do contrário, o *reset* é ativado e o *match tracking* dará início ao processo de ajuste do parâmetro de vigilância do módulo ART_a (ρ_a) e acionará a busca por uma nova categoria em ART_a para ser combinada com a categoria atual de ART_b (CARPENTER; GROSSBERG; REYNOLDS, 1991).

Também no módulo inter-ART ocorre a adaptação dos pesos entre as categorias ativas dos módulos ART_a e ART_b . Esse processo de ajuste é realizado por meio da atribuição de um valor igual a 1 (um) para as categorias ativas e um valor igual a zero para as categorias que não foram ativadas (CARPENTER; GROSSBERG; REYNOLDS, 1991).

Figura 10 - Esquema simplificado da rede neural ARTMAP.



Fonte: Adaptação (AMORIM, 2006)

4.3 REDE NEURAL ARTMAP EUCLIDIANA

Tal como a arquitetura ARTMAP, a RNA ARTMAP Euclidiana é igualmente composta por um par de módulos ART, todavia essa estrutura se distingue acerca de diversos ângulos da modelagem tradicional. Esta rede emprega em seu algoritmo a distância euclidiana com o intuito de arbitrar se determinado padrão está distante ou perto das classes existentes, na condição de próximo, este é inserido nesta categoria e a sua localização é atualizada. De outro modo, a rede pode permitir a criação de uma nova categoria com base nesta entrada, por julgá-la distante o bastante das classes já existentes (KENAYA; CHEOK, 2008b). Portanto, as categorias na RNA Euclidiana são determinadas por uma função que está alicerçada na equação da distância euclidiana (1), (2), entre dois pontos dentro de um espaço p -dimensional:

$$d_E(x, y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_p - y_p)^2} \quad (1)$$

$$= \sqrt{(x - y)(x - y)^T}$$

$$d_E(x, 0) = \|x\|_2 = \sqrt{x_1^2 + x_2^2 + \dots + x_p^2} = \sqrt{x x^T} \quad (2)$$

sendo:


$$x = [x_1 \ x_2 \ \dots \ x_p];$$

$$y = [y_1 \ y_2 \ \dots \ y_p].$$

A RNA ARTMAP Euclidiana, visa maior precisão nos resultados com um tempo de processamento mínimo. Assim esta arquitetura, diferentemente da modelagem clássica, abstém-se dos passos de normalização e codificação em complemento das entradas, sendo esta uma das características promissoras desta rede, pois este aspecto reflete diretamente no gasto computacional deste modelo.

Na arquitetura ARTMAP baseada na distância euclidiana, a seleção da categoria candidata opera com a minimização em oposto ao utilizado nas redes ART e ARTMAP que adotam a maximização. Outro aspecto em que se distingue está na representação geométrica das categorias, uma vez que, este modelo neural não utiliza hiper-retângulos como nos modelos clássicos, mas sim hiper-esferas (Figura 11) em razão da incapacidade que os retângulos teriam para retratar os padrões desta arquitetura (CARPENTER, ROSS, 1995).

Figura 11 – Representação geométrica em hiper-esferas.



Fonte: (AMORIM, 2006).

As concepções baseados na teoria da ressonância adaptativa empregam alguns critérios, os quais executam atribuições específicas nos procedimentos de treinamento e diagnóstico desses modelos neurais (CARPENTER; GROSSBERG, 1987):

- *Parâmetro de escolha* (α) - exerce influência na escolha de categorias.
- *Taxa de treinamento* (β) - estipula a agilidade no processamento neural.
- *Parâmetro de vigilância* (ρ) - exerce controle sobre a ressonância adaptativa nos módulos ART_a , ART_b e Inter-ART.

Além dos critérios supracitados, os modelos da família ART também aplicam um fator cujo propósito é realizar um ajuste de forma dinâmica no parâmetro de vigilância do módulo ART_a , se porventura houver conveniência. Na modelagem clássica, o parâmetro ε (ajuste de ρ_a) é incrementado, já na arquitetura euclidiana, por ser aderida a minimização, ρ_a é decrementado. Além disso, tal como já reportado neste estudo, o algoritmo desta rede aplica a distância euclidiana no método de escolha das categorias, portanto, este modelo dispensa a uso do parâmetro de escolha (α). Isso posto, o Quadro 2 expõe os critérios utilizados na rede neural ARTMAP Euclidiana (CARPENTER, ROSS, 1995).

Quadro 2 - Parâmetros da Rede Neural ARTMAP Euclidiana

Parâmetro	Nomenclatura	Valores
Taxa de treinamento	B	$\beta \in [0, 1]$
Parâmetro de vigilância Módulo ART_a	ρ_a	$\rho_a \in [0, 1]$
Parâmetro de vigilância Módulo ART_b	ρ_b	$\rho_b \in [0, 1]$
Parâmetro de vigilância Módulo Inter-ART	ρ_{ab}	$\rho_{ab} \in [0, 1]$
Decremento de ρ_a	ε	Próximo de 0 (zero)

Fonte: Elaborado pela própria autora.

Outro aspecto a ser observado está na etapa de concepção dos pesos iniciais, uma vez que, na abordagem Euclidiana, as matrizes correspondentes aos módulos ART_a e ART_b se iniciam com valor igual a 0 (zero), indicando a existência se somente uma categoria ativa. Quanto ao módulo inter-ART, w_{jk}^{ab} recebe o valor 1 (um), sinalizando a ausência de

categorias ativas. Já na modelagem tradicional, as matrizes w_j^a , w_k^b e w_{jk}^{ab} se iniciam recebendo um valor igual a 1 (um), apontando a não ativação de categorias (CARPENTER, ROSS, 1995).

O algoritmo da RNA ARTMAP Euclidiana, se dá por meio de uma série de passos que empregam diferentes funções (CARPENTER, ROSS, 1995), assim, após as etapas de leitura dos padrões de entrada (I_a) e saída desejada (I_b), construção dos pesos iniciais (w_j^a , w_k^b e w_{jk}^{ab}) e leitura dos parâmetros ($\beta, \rho_a, \rho_b, \rho_{ab}, \varepsilon$), essa sequência prossegue da seguinte forma:

1º) Função categoria - Inicia o processamento da rede, a equação (3) é executada nos blocos ART_a e ART_b viabilizando a associação de padrões e a geração de classes com base nos conjuntos de entrada (I_a) e saída desejada (I_b) fornecidos a rede.

$$T_j^a = (I_a - w_j^a) (I_a - w_j^a)^T \quad (3)$$

$$T_k^b = (I_b - w_k^b) (I_b - w_k^b)^T$$

2º) Escolha da categoria - a equação (4) garante que as categorias ativadas nos módulos ART_a (J) e ART_b (K) serão as que manifestarem ativação mínima.

$$T_j^a = \min\{T_j: j = 1, \dots, N\} \quad (4)$$

$$T_k^b = \min\{T_k: k = 1, \dots, N\}$$

3º) Teste de vigilância – a equação (5) tem a finalidade de fiscalizar se as categorias ativadas nos módulos ART_a (J) e ART_b (K) atendem a norma de vigilância da rede. Caso contrário, um o procedimento de “reset” é executado e atribuindo um valor nulo (zero) para esta classe. Assim, o reset é executado até que se encontre uma categoria que satisfaça a vigilância da rede.

$$\frac{T_j^a}{\max(I_j^a I_j^{aT}, w_j^a w_j^{aT})} < \rho_a \quad (5)$$

$$\frac{T_K^b}{\max(I_K^b I_K^{b^T}, w_K^b w_K^{b^T})} < \rho_b$$

4º) Vetor atividade da ART_b - a equação (6) forma um vetor que representa as categorias criadas no módulo ART_b . Este procedimento será executado somente quando a categoria ativa K atender a função de vigilância.

$$y_K^b = [y_1^b \ y_2^b \ \dots \ y_N^b] \quad (6)$$

para:

$$y = \begin{cases} y_k^b = 0, & \text{se } k \neq K \\ y_K^b = 1, & \text{se } k = K \end{cases}$$

5º) Inter-ART (*Match-Tracking*) - a equação (7) tem a função de verificar se existe consonância entre as informações processadas nos módulos ART_a e ART_b .

$$|y^b \wedge w_j^{ab}| \leq \rho_{ab} \quad (7)$$

6º) Vetor atividade da ART_a - a equação (8) é executada somente quando *match-tracking* é atendido, assim, um vetor que representa as categorias criadas no módulo ART_a é gerado.

$$y_J^a = [y_1^a \ y_2^a \ \dots \ y_N^a] \quad (8)$$

para:

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

7º) Atualização dos pesos - quando a etapa de treinamento é finalizada, as matrizes pesos correspondentes aos módulos $ART_a(w_J^a)$, $ART_b(w_K^b)$ e inter-ART (w_{JK}^{ab}) são atualizadas segundo a ordem das equações (9), (10) e (11).

$$w_K^{b\ novo} = \beta(I_K^b) + (1 - \beta)w_K^{b\ velho} \quad (9)$$

$$w_j^{a\ novo} = \beta(I_j^a) + (1 - \beta)w_j^{a\ velho} \quad (10)$$

$$w_{jK}^{ab} = [y_1^{ab} \ y_2^{ab} \ \dots \ y_N^{ab}] \quad (11)$$


para:

$$y_{jk}^{ab} = \begin{cases} 0, & \text{se } j \neq J; \text{ se } k \neq K \\ 1, & \text{se } j = J; \text{ se } k = K \end{cases}$$

8º) Decremento de ρ_a - a equação (12) é utilizada somente quando o *match-tracking* não é satisfeito, assim, após o procedimento de *reset*, essa função é utilizada com a intuito de adequar o norma de vigilância de ART_a , aplicando um decréscimo previamente estipulado em ρ_a .

$$\rho_a = \frac{T_j^a}{\max(I_j^a \ I_j^{aT}, w_j^a \ w_j^{aT})} - \varepsilon \quad (12)$$

Figura 12 – Fluxograma do algoritmo da RNA ARTMAP Euclidiana.




Fonte: Adaptação (GOMES, 2017).

5 REDE NEURAL EUCLIDIANA APLICADA AO PROBLEMA DE PREVISÃO DE CARGAS ELÉTRICAS

Com o intuito de prover a antecipação da demanda de cargas elétricas de forma multinodal e a curto prazo, este estudo utiliza uma concepção neural que se baseia na distância Euclidiana para compor a um Sistema Previsor de Cargas de Subestação (SPCS), cuja estrutura é formada por diversos blocos que realizam a previsão de forma autônoma. Cada módulo deste sistema compõe-se de uma RNA ARTMAP Euclidiana, que recebe como entrada os dados históricos de cargas elétricas e um conjunto de elementos exógenos que refletem o comportamento dessas cargas. A Figura 13 ilustra o sistema proposto.

Figura 13 – Esquema de sistema previsor de carga multinodal.



Fonte: Elaborado pela própria autora.

Como exposto na Figura 13, neste estudo empregou-se dois grupos de dados para compor as séries de padrões de entrada oferecidos à RNA ARTMAP Euclidiana, são eles: dados exógenos e dados de cargas locais. Dos quais, os elementos exógenos utilizados foram: dia da semana, hora, cargas média, mínima e máxima no instante h , sendo que h é representado pelo período de $\frac{1}{2}$ hora.

O Quadro 3 ilustra a configuração utilizada para os dados exógenos utilizados neste trabalho. É possível observar que os dados que estão diretamente relacionados no tempo, instante h , ou seja, de meia em meia hora. Desta forma, tem-se que para uma representação

binária do instante h será necessário a utilização de 6 bits para representação de um dia, ou seja:

$\frac{1}{2}$ hora – [000001]

1 hora – [000010]

1 $\frac{1}{2}$ hora – [000011]

...

totalizando em 48 informações que representam a informação hora que será um dos dados de entrada das variáveis exógenas.

Observa-se que também foram utilizadas as informações de cargas elétricas máximas e mínimas em um banco de dados históricos e estes foram usados como uma informação de variação histórica de cargas elétricas, mínimas e máximas, que estariam ocorrendo no período de 1 hora. Para completar esta análise também é utilizada a carga média que é definida como sendo a média das cargas elétricas nos instante h em um período de 1 hora. Estas informações são importantes no contexto de controlar a variabilidade da carga.

Portanto, para estimar a carga 24 horas a frente, refere-se a um vetor composto por 48 valores de cargas elétricas previstas a cada $\frac{1}{2}$ hora.

Quadro 3 - Dados exógenos utilizados no conjunto de entrada da rede RNA ARTMAP Euclidiana.


Dados Exógenos	Informação
Dia da Semana (3bits)	[001] – Segunda-feira
	[010] – Terça- feira
	[011] – Quarta-feira
	[100] – Quinta-feira
	[101] – Sexta-feira
	[110] – Sábado
	[111] – Domingo
Hora (6 bits)	[000001] – 1 informação (1/2 hora) ⋮ ⋮ [110000]– 48 informações (24 * (1/2 hora))

Carga Média	$CM(k+1) = \frac{\sum_{i=1}^2 L(k+i \cdot h)}{2}, \text{ para } k = 0, 1, 2, \dots, 23$ Este procedimento é realizado para o período de cada hora.
Carga Mínima	$\text{Min}(L(k+1 \cdot h), L((k+2 \cdot h))) \text{ para } k = 0, 1, 2, \dots, 23$
Carga Máxima	$\text{Max}(L(k+1 \cdot h), L((k+2 \cdot h))) \text{ para } k = 0, 1, 2, \dots, 23$

Fonte: Elaborado pela própria autora.

Quanto aos dados de cargas, adotou-se o método do movimento em janela, sendo este tipicamente utilizado como estratégia para realizar previsões na área de cargas elétricas, cujo deslocamento é determinado de acordo os horizontes da previsão (PARK; SHARKAWI; MARK II, 1991). Assim, neste estudo, conforme demonstrado na Figura 14, arbitrou-se na série temporal, um deslocamento de três janelas.

Figura 14 - Esquema do deslocamento de janelas.



Fonte: Elaborado pela própria autora.

Então, levando em consideração os dados de cargas no instante h (1/2 hora) tem-se a utilização em uma estrutura de janela composta por cargas elétricas nos seguintes instantes: L(h-3), L(h-2), L(h-1) e L(h), que serão agregadas ao conjunto de variáveis exógenas com o objetivo de obter a previsão de carga do instante posterior, ou seja, L(h+1). É importante

menção de que desta forma serão obtidas 48 informações de cargas elétricas obtidas de ½ em ½ hora. A equação (13) representa o vetor utilizado.

$$X(h) = [t \ L(h-3) \ L(h-2) \ L(h-1) \ L(h)]^T, X \in \mathbb{R}^m$$

e

(13)

$$Y(h) = [L(h+1)], Y \in \mathbb{R}^1$$

sendo:

m : simboliza a dimensão do vetor X ;

$L(h-q)$: valor da carga q instantes, antecedente a carga elétrica no instante h ;


$L(h+1)$: valor da carga referente ao instante subsequente à carga no instante h ;

t : vetor de tempo respectivo aos dados históricos;

h : instante retratado em ½ hora.

A Figura 15 esquematiza a metodologia para a previsão de carga multinodal, apresentada nesta pesquisa.

Figura 15 - Esquema do modelo da previsão proposto.



Fonte: Elaborado pela própria autora.

A metodologia proposta neste estudo é feita em dois procedimentos distintos, sendo: treinamento e previsão. No processo de treinamento, $Y(h)$ representa a carga elétrica ½ hora à frente, já na fase da previsão esse vetor de saída corresponde à carga prevista ½ hora à frente na forma binária.

A base de dados das séries históricas do consumo de energia elétrica da *Electricity Commission* contém valores de cargas ativas medidas a cada meia hora e referências exógenas como dia do mês, mês, ano, dia da semana, feriado e horário de verão. Esses dados foram coletados de cada uma das nove subestações, em um período compreendido em janeiro de 2007 a março de 2009. Nesta pesquisa utilizou-se informações de 2007, de acordo com o exposto no Quadro 4.

Quadro 4 - Divisão do banco de dados.

Banco de Dados	Período (dd/mm/aaaa)
Treinamento	15/10/2007 a 29/10/2007
Previsão	30/10/2007

Fonte: Elaborado pela própria autora.

Conforme o período de dados exposto, a saída do sistema previsor, apresentado neste trabalho, será formada por um vetor composto por 48 elementos que correspondem a valores das cargas elétricas a cada $\frac{1}{2}$ hora.

Foram realizados dois tipos de previsão de carga elétrica:

1. Previsão global: no qual se pretende estimar o consumo de carga elétrica total do sistema;
2. Previsão local: no qual se deseja estimar o consumo de carga elétrica de forma desagregada, por exemplo, barramento, subestação, etc.

Neste trabalho abordou-se a previsão de carga global e a previsão de carga multinodal realizadas para nove subestações. A rede neural Euclidiana manteve a mesma estrutura de entrada e saída de dados, equação (13), com a utilização de dados exógenos fornecidos pelo Quadro 3. Ressalta-se que a diferença entre aos dois tipos de previsões analisadas neste trabalho refere-se à carga elétrica, $L(.)$, utilizada sendo que:


- Previsão Global: utiliza-se o valor de carga global do sistema no instante h ;
- Previsão Multinodal: utiliza-se o valor de carga de cada subestação no instante h .

Os valores dos parâmetros fornecidos às RNAs durante a fase de treinamento são de essencial importância, pois exercem forte influência nos resultados das previsões. Desta

forma, busca-se a melhor combinação entre esses critérios a fim de obter resultados satisfatórios. No que se refere à rede neural ARTMAP Euclidiana, por meio dos testes realizados nesta pesquisa, pouco se observou a influência de ρ_a e ρ_{ab} no comportamento desta metodologia, em razão disso, foi mantido um valor fixo de 0,15 para esses parâmetros, assim como adotado no estudo realizado por Gomes (2017). Do mesmo modo, o parâmetro ε que realiza o decremento em ρ_a quando o *Match-Tracking* não é satisfeito, foi mantido no valor de 0,0001 devido ao baixo impacto que ρ_a proporcionou nas análises realizadas neste trabalho por meio da randomizando dos valores deste critério.

Quanto β e ρ_b observou-se grande intervenção dos mesmos no comportamento da rede neural Euclidiana, desta forma, estes parâmetros foram obtidos através de um bloco acoplado a rede neural, responsável por realizar a busca automática pelo melhor valor para β e ρ_b de forma a obter um MAPE previamente estabelecido. A busca pelos valores desses parâmetros foi realizada dentro de um intervalo pré-definido, obtido através da análise dos testes realizados com a RNA Euclidiana com valores randômicos para ambos os critérios, desta forma, foi mantido o intervalo ao qual os parâmetros pertencem, visando manter uma combinação satisfatória com os demais critérios da rede neural. A Figura 17 expõe o fluxograma da RNA ARTMAP Euclidiana com ajuste de parâmetros automático, utilizada neste trabalho.

Figura 17 - Fluxograma da RNA ARTMAP Euclidiana com ajuste automático de parâmetros.



Fonte: Elaborado pela própria autora.

A RNA ARTMAP Euclidiana, possui características em sua arquitetura que proporcionam um tempo computacional bastante reduzido, se comparado às modelagens tradicionais que utilizam os processos de normalização e codificação complementar dos padrões de entrada, desta forma, torna-se viável implementar um ajuste automático dos parâmetros deste modelo neural, uma vez que, nos testes realizados neste estudo, observou-se um tempo médio de processamento de 16,8 minutos para a procura dos melhores valores para β e ρ_b , visando previsões com MAPEs inferiores a 5%. Contudo, trata-se de um sistema randômico, cujo tempo computacional pode variar de acordo com o período estipulado e com o grau de exigência nos resultados.

Assim, as simulações no sistema previsor global e no sistema previsor de carga por subestação foram realizadas automatizando o algoritmo da Rede Neural Euclidiana, para realizar a busca de resultados de acordo um valor de MAPE pré-estipulado. Nesta pesquisa, objetivou-se obter valores abaixo de 5% em todos os casos analisados, visando resultados significativos e de baixo impacto econômico. A Tabela 1 expõe os parâmetros utilizados no sistema previsor global.

Tabela 1 - Parâmetros utilizados no sistema previsor global.

Sistema previsor	β	ρ_a	ρ_b	ρ_{ab}	ϵ
<i>Dados Globais</i>	0,9777	0,15	0,0000001	0,15	0,0001

Fonte: Elaborado pela própria autora.

A Tabela 2 mostram-se os parâmetros adotados no decorrer da fase de treinamento da RNA Euclidiana no Sistema Previsor de Cargas de Subestação (SPCS).


Tabela 2 - Parâmetros utilizados por subestação.

Sistema previsor	β	ρ_a	ρ_b	ρ_{ab}	ϵ
<i>Sub1</i>	0,97822	0,15	0,00000001	0,15	0,0001
<i>Sub2</i>	0,9836372	0,15	0,0000000001	0,15	0,0001
<i>Sub3</i>	0,979999	0,15	0,0000000001	0,15	0,0001
<i>Sub4</i>	0,97622	0,15	0,00000001	0,15	0,0001
<i>Sub5</i>	0,98762	0,15	0,00000001	0,15	0,0001
<i>Sub6</i>	0,99983	0,15	0,00000001	0,15	0,0001
<i>Sub7</i>	0,99764	0,15	0,00000001	0,15	0,0001
<i>Sub8</i>	0,99874	0,15	0,00000001	0,15	0,0001

Sub9	0,946992	0,15	0,00000001	0,15	0,0001
Fonte: Elaborado pela própria autora.					

A eficiência da metodologia proposta pode ser analisada por meio da comparação entre a curva da carga prevista e a curva da carga real. Assim, nesta pesquisa, o esboço de ambas as curvas foi realizado considerando-se 48 dados de cargas, que corresponde ao período de um dia (24 horas) em intervalos de 30 minutos. Desta forma, a curva de carga real é apresentada na cor azul e a curva de carga prevista é indicada na cor vermelha. A Figura 18 ilustra a curva de carga real e prevista, obtidas por meio da carga global.


Figura 18 - Curva de carga real e prevista da carga global.




Fonte: Resultados da pesquisa.

As ilustrações apresentadas na Figura 19 correspondem à curva de carga real e à curva prevista das subestações: (a) Kopu, (b) Waikino, (c) Waihou, (d) Hamilton 11 kV, (e) Hamilton 33 kV, (f) Cambridge, (g) Te Awamutu, (h) Hinuera e (i) Kinleith.


Figura 19 - Conjunto de curvas de cargas previstas por subestação.




(a)




(b)




(c)




(d)




(e)




(f)



(g)



(h)



(i)

Fonte: Resultados da pesquisa.

Através do conjunto de ilustrações apresentadas nas Figuras 18 e 19 é possível observar que as curvas das cargas elétricas previstas (vermelho) estão bastante próximas das curvas formadas pelas cargas reais (azul). Isso ocorre tanto na previsão da carga global quanto na multimodal (por subestações) o que mostra um desempenho eficaz da ferramenta proposta neste trabalho.

A análise de desempenho também pode ser realizada com base nas métricas MAPE (*Medium Absolute Percentual Error*) e erro máximo. A Tabela 3 expõe os resultados obtidos com essas estimativas, bem como o tempo de processamento do sistema predictor global.

Tabela 3 - Resultados obtidos no sistema predictor global.

Tempo (s)	MAPE (%)	Erro Máximo (%)
1,41	0,62	2,43

Fonte: Elaborado pela própria autora.

A Tabela 4 evidencia o tempo de processamento, o MAPE e o erro máximo obtidos no Sistema Predictor de Cargas de Subestação.

Tabela 4 - Resultados obtidos no sistema predictor por subestação.

Sistema predictor	Tempo (s)	MAPE(%)	Erro Máximo(%)
<i>Sub1</i>	10,95	1,25	7,55
<i>Sub2</i>	11,45	1,76	10,94
<i>Sub3</i>	14,02	1,93	9,60

<i>Sub4</i>	11,24	1,34	3,56
<i>Sub5</i>	12,52	1,03	5,69
<i>Sub6</i>	10,47	1,56	6,99
<i>Sub7</i>	12,49	1,43	5,65
<i>Sub8</i>	14,81	2,00	7,22
<i>Sub9</i>	13,60	3,32	13,82

Fonte: Elaborado pela própria autora.

A Tabela 5 expõe o número de neurônios criados durante a fase de treinamento para cada subestação e também, para a carga global.


Tabela 5 - Quantidade de neurônios

Sistema previsor	Número de neurônios
<i>Sub1</i>	662
<i>Sub2</i>	711
<i>Sub3</i>	711
<i>Sub4</i>	665
<i>Sub5</i>	662
<i>Sub6</i>	645
<i>Sub7</i>	670
<i>Sub8</i>	647
<i>Sub9</i>	685
<i>Global</i>	714

Fonte: Elaborado pela própria autora.

Através do somatório das cargas previstas em cada subestação é possível obter a carga global do sistema. A Figura 20 ilustra a carga global real e a carga global prevista obtida por meio da soma das cargas desagregadas.

Figura 20 - Curva de carga global real e prevista pelo somatório das subestações.



Fonte: Resultados da pesquisa.

A Tabela 6 expõe os resultados alcançados através dos dados globais do sistema, em comparação aos valores obtidos utilizando a carga global, adquirida mediante a soma das cargas previstas em todas as subestações.

Tabela 6 - Comparação entre as cargas globais

Sistema predictor	MAPE (%)	Erro Máximo (%)
<i>Dados Globais</i>	0,62	2,43
<i>Soma Global</i>	0,76	2,79

Fonte: Elaborado pela própria autora.

Através da Tabela 6 é possível observar os erros (MAPE e erro máximo) obtidos da previsão global obtidas de formas diferentes:

1. Dados Globais: baseiam-se no cálculo da previsão de carga elétrica global: utilizando a rede neural Euclidiana tomando como dados de entrada e saída da rede os valores de cargas elétricas globais;
2. Soma Global: Neste caso, a previsão de carga elétrica global é obtida através do somatório das previsões de cargas elétricas multinodais (subestações) sendo que, cada previsão multinodal foi obtida através da rede neural Euclidiana sendo que os dados de entrada e saída utilizados foram baseados em valores de cargas elétricas da subestação analisada.

Observando os erros obtidos na previsão de carga global tem-se que não existe uma diferença significativa entre os resultados obtidos pelas duas metodologias propostas quando

utilizada a rede neural ARTMAP Euclidiana. Este é um ponto positivo, pois a previsão de carga elétrica desagregada é mais complexa, uma vez que surgem mais características do sistema, ou variáveis exógenas que interferem no modelo, tornando os cálculos mais complexos e ocasionando o aparecimento de outros fatores que, por sua vez influenciam negativamente nos resultados, tornando a previsão mais suscetível ao erro.

Na tabela 4 é possível observar a robustez desta arquitetura neural na previsão multinodal com um percentual de erro inferior a 2% nas previsões de cargas elétricas em aproximadamente 80% das subestações.

Portanto, com a metodologia proposta neste trabalho, observa-se que oito entre as nove subestações estudadas obtiveram ótimos resultados ficando com o MAPE inferior ou igual a 2% e a carga global apresentou um erro percentual médio absoluto inferior a 1%. De forma geral, os MAPEs obtidos nesta pesquisa ficaram abaixo de 3,5%, o que comprova o baixo impacto econômico da ferramenta proposta, uma vez que conforme estudo realizado em Ranaweera, Karady e Farner (1997), a carga prevista deve manifestar o erro percentual médio absoluto (MAPE) abaixo de 5% para ser considerada precisa e de baixo impacto econômico, haja vista que o alto grau de imprecisão na demanda pode repercutir em um aumento expressivo nos custos operacionais do SEP.

Ressalta-se também, que a rede neural ARTMAP Euclidiana apresentou um tempo computacional inferior a 15 segundos para processar dados em amostras medidas a cada meia hora, totalizando 750 padrões apresentados na fase de treinamento, comprovando a rapidez da arquitetura neural Euclidiana, visto que, demonstrou necessitar de um tempo de processamento muito inferior ao que se observa nos resultados correlatos disponíveis na literatura.

7 CONSIDERAÇÕES FINAIS

A eletricidade move o mundo contemporâneo e a demanda por energia tem se tornado cada vez maior no decorrer dos anos, desta forma, torna-se essencial realizar estudos no sentido de garantir o bom funcionamento deste mercado no futuro.

Dessa forma, este trabalho apresenta uma metodologia desenvolvida via Redes Neurais Artificiais, aplicada ao problema de previsão de carga multimodal, isto é, cuja abordagem propõe conhecer a distribuição das cargas entre os diversos pontos da rede elétrica, visando obter informações de forma mais significativa e aprofundada dos sistemas de transmissão.

A arquitetura proposta se baseia na rede neural ARTMAP Euclidiana, que utiliza um processo automático por meio da modificação de parâmetros, visando obter um resultado previamente definido sem a necessidade de intervenção humana. Assim, nesta pesquisa objetivou-se atingir erros percentuais médios absolutos inferiores a 5%, com a finalidade de obter resultados significativos em termos de impacto da previsão.

Os resultados comprovaram que se trata de uma metodologia promissora, cujos MAPEs obtidos para as nove subestações analisadas ficaram abaixo de 3,5%, das quais, oito subestações obtiveram resultados inferiores a 2%. No que se refere à carga global, esta apresentou um erro percentual médio absoluto inferior a 1%, o que evidencia que a ferramenta apresentada neste estudo é bastante significativa na problemática da previsão de cargas elétricas, se defrontado com outros estudos referentes a este tema disponíveis na literatura especializada. Portanto, é possível avaliar que o modelo elaborado neste estudo é capaz de realizar prognósticos de cargas elétricas dentro de diversos aspectos do sistema elétrico de potência, atingindo resultados com alta precisão, baixo impacto econômico e custo computacional reduzido, sem a necessidade de intervenção humana de forma ativa.

Não foram encontrados na literatura especializada estudos que utilizam a Rede Neural ARTMAP Euclidiana aplicada à previsão de carga multinodal. Assim, as principais contribuições deste trabalho refere-se ao desenvolvimento de um Sistema Previsor de Carga de Subestações (multimodal) composto por uma arquitetura neural ARTMAP baseada na distância euclidiana que, devido às características de seu algoritmo, é capaz de realizar previsões com o esforço computacional bastante reduzido, uma vez que se isenta dos passos de normalização e codificação complementar dos dados de entrada diminuindo o tempo necessário na manipulação das informações.

Além disso, este estudo apresenta uma perspectiva inovadora para as RNAs trazendo o conceito de automatização dos parâmetros de modelos neurais, o que proporciona como constatado nesta pesquisa, maior praticidade e eficiência no processo de ajuste dos critérios fornecidos à rede neural na fase de treinamento, oportunizando melhores combinações e consequentemente resultados mais significativos.

Outro ponto relevante encontra-se na análise apresentada nesta pesquisa sobre a influência dos parâmetros na arquitetura neural ARTMAP Euclidiana, onde se constatou um comportamento diferenciado desses critérios quando aplicados a este modelo neural, apresentando grande distinção em relação às outras arquiteturas da família ARTMAP.

Assim, ressalta-se a importância deste trabalho, haja vista, a ausência na literatura técnica de trabalhos segundo a metodologia apresentada nesta pesquisa e com resultados correlatos obtidos com a mesma relevância em termos de precisão, rapidez e confiabilidade.

Entre as sugestões de trabalhos futuros que podem ser elaborados com base neste estudo, destacam-se:

- a) Realizar modificações no janelamento das cargas elétricas;
- b) Inserir outros dados exógenos de entrada da rede, como: a temperatura, feriados e horário de verão;
- c) Realizar um estudo aprofundado sobre a influência dos parâmetros na RNA Euclidiana.
- d) Realizar a automatização dos parâmetros de outros modelos neurais, como a ARTMAP *Fuzzy*.

7.1 ARTIGO PUBLICADO

FERREIRA A. B. A. et al. **Multinodal Load Forecast Using Euclidean ARTMAP Neural Network**, 2019 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America), Gramado, Brazil, 2019, pp. 1-6.

REFERÊNCIAS

- AMBER, K. P. et al. Intelligent techniques for forecasting electricity consumption of buildings. **Energy**, Rondebosch, v. 157, p. 886-893, 2018.
- ALTRAN, A.B. **Sistema Inteligente Para Previsão de Carga Multinodal em Sistemas Elétricos de Potência**. 2010. 87 f. Tese (Doutorado em Engenharia Elétrica) - Departamento de Engenharia Elétrica, UNESP – Universidade Estadual Paulista, Ilha Solteira-SP, Brazil, 2010.
- AMJADY, N. Short-Term Bus Load Forecasting of Power Systems by a New Hybrid Method. **IEEE Transactions on Power Systems**, New York, v. 22, n. 1, p. 333-341, Feb. 2007. DOI: 10.1109/TPWRS.2006.889130
- AMORIM, A. J. **Previsão de carga multinodal formulada via rede neural baseada na teoria da ressonância adaptativa com treinamento direto e reverso**. 2019. 90 f. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2019.
- AL-KANDARI, A. M.; SOLIMAN, S. A.; EL-HAWARY, M. E. *Fuzzy* short term electric load forecasting. **Electric Power & Energy Systems**, [s. l.], v. 26, n. 2, p. 111-122, 2004.
- ANTUNES, J. F. **Previsão de carga multinodal usando a rede neural ART-ARTMAP fuzzy**. 2013. 110 f. Tese (Doutorado em Engenharia Elétrica) - Departamento de Engenharia Elétrica, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2013.
- ANDERSON, J. A. **An introduction to neural networks**. Cambridge: The MIT Press, 1995.
- AMORIM, D. G. **Redes ART com categorias internas de geometria irregular**. 2006. Tese (Doutorado em Física) - Universidade de Santiago de Compostela, Santiago de Compostela, 2006.
- ABREU, T. **Previsão de cargas elétricas através de um modelo híbrido de regressão com redes neurais**. 2012. 62 f. Dissertação (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2012.
- BOX, G. E.; JENKINS, G. M. **Time series analysis: forecasting and control**. Holden-Day: San Francisco, 1976.
- BUNN, D.W.; FARMER, E. D. **Comparative models for electrical load forecasting** Wiley: New York, 1985.
- BARROS, A. C. et al. Detection and classification of voltage disturbances in electrical power systems using a modified euclidean ARTMAP neural network with continuous training. **Electric Power Components and Systems**, Philadelphia, v. 43, n. 19, p. 2178-2188, 2015. DOI:10.1080/15325008.2015.1073814

CSIRO. The Natural Edge Project. **Energy transformed**: sustainable energy solutions for climate change mitigation, Austrália, 2007. 6 p.

CHAE, Y. T. et al. Artificial neural network model for forecasting sub-hourly electricity usage in commercial buildings. **Energy and Buildings**, Amsterdam, v. 111, p. 184-194, 2016.

CARPENTER, G. A.; GROSSBERG, S. ART2: Stable self-organization of pattern recognition, codes for analog input patterns. **Applied Optics**, New York, v. 26, n. 23, p. 4919-4930, 1987.

CARPENTER, G. A.; GROSSBERG, S. The ART of Adaptive Pattern Recognition by a Self-Organizing Neural Network. **Computer**, Pistacaway, v. 21, n. 3, p. 77-88, 1988.

CARPENTER, G. A. et al. ARTMAP: supervised real-learning and classification of non-stationary data by a self organizing neural network. **Neural Network**, Kidlington, v. 4, n. 5, p. 565-588, 1991.

CARPENTER, G. A.; GROSSBERG, S.; ROSEN D. B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. **Neural Network**, Kidlington, v. 4, n. 1, p. 759-771, 1991.

CARPENTER, G. A.; GROSSBERG, S. And REYNOLDS, J. H. ARTMAP: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network. **Neural Networks**, Kidlington, v. 4, 565-588, 1991.

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

CARPENTER, G. A.; GROSSBERG, S. A self-organizing neural network for supervised learning, recognition and prediction. **IEEE Communications Magazine**, Piscataway, v. 30, n. 9, p. 38-49, 1992.

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

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

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

DEB, C. et al. Forecasting Energy Consumption of Institutional Buildings in Singapore. **Procedia Engineering**, Amsterdam, v. 121, p. 1734-1740, 2015.

DAMBORG, M. J. et al. Potential of artificial neural network to power system operation. *In: IEEE INTERNATIONAL SYMPOSIUM ON CIRCUITS AND SYSTEMS*, 1990, New Orleans. **Proceedings** [...] New Orleans: [s. n.], 1990. p. 2933- 2937.

FINE, T. L. **Feedforward neural network methodology**. New York: Springer-Verlag, 1999.

FAUSETT, L. **Fundamentals of neural networks**: architectures, algorithms, and applications, englewood cliffs. New York: Prentice Hall, 1994.

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

GOMES, T. T. **Rede ARTMAP euclidiana utilizada na solução do problema de previsão de cargas elétricas**. 2017. 90 f. Dissertação (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2017.

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

GOPAL, S.; WOODCOCK, C. E; STRAHLER, A. H. Fuzzy neural network classification of global land cover from a 1- Degree AVHRR Data Set. **Remote Sensing of Environment**, New York, v. 67, n. 2, p. 230-243, 1999.

HONG, T. Energy forecasting: past, present, and future. **Foresight: The International Journal of Forecasting**, [s. l.], v. 32, p. 43-49. 2014.

HONG, T.; FAN, S. Probabilistic electric load forecasting: a tutorial review. **International Journal of Forecasting**, [s. l.], v. 32, n. 3, p. 914-938, 2016.
DOI:10.1016/j.ijforecast.2015.11.011.

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

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. **Proc. of the National Academy of Sciences**, New York, v. 79, p. 2554-2558, 1982.

JOVANOVIĆ, R. Ž.; SRETENOVIĆ, A. A.; ŽIVKOVIĆ, B. D. Ensemble of various neural networks for prediction of heating energy consumption. **Energy Build.**, [s. l.], v. 94, p. 189–199, 2015.

KUSTER, C.; REZGUI, Y.; MOURSHED, M. Electrical load forecasting models: A critical systematic review. **Sustainable Cities and Society**, v. 35, p. 257-270, 2017.
DOI:10.1016/j.scs.2017.08.009

KUNDUR, P. **Power system stability and control**. New York: McGraw-Hill, 1994.

KOVÁCS, Z. L. **Redes neurais artificiais**: fundamentos e aplicações. [S. l: s. n.], 1996.

KENAYA, R.; CHEOK, K. C. Euclidean ARTMAP based target tracking control system, 2008 **IEEE International Conference on Electro/Information Technology**, Ames, IA, p. 41-47, 2008a. doi: 10.1109/EIT.2008.4554265.

KENAYA, R.; CHEOK, K. **Euclidean ART Neural Networks**. [S. l.]: Lecture Notes in Engineering and Computer Science. 2008b. 2173 p.

KROSE, B.; SMAGT, P.V. **Na introduction to neural networks**. 8. ed. Amsterdam: Online Book, University of Amsterdam, 1996.

KOHONEN, T., The self-organizing map. **Proceedings of the IEEE**, New York, v. 78, n. 9, 1990.

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

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

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

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

MOGHARAM, 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.

MORENO, A. L. **Análise da estabilidade transitória via rede neural ART-ARTMAP fuzzy euclidiana modificada com treinamento continuado**. 2010. 143 f. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP Ilha Solteira, 2010.

MARINESCU, A. *et al.* Residential electrical demand forecasting in very small scale: An evaluation of forecasting methods. *In: INTERNATIONAL WORKSHOP ON SOFTWARE ENGINEERING CHALLENGES FOR THE SMART GRID*, 2nd, 2013, New York. **Proceedings** [...] New York: [s. n.], 2013. p. 25–32.

MARCHIORI, S. C. *et al.* Neural network based on adaptive resonance theory with continuous training for multi-configuration transient stability analysis of electric power systems. **Applied Soft Computing**, [s. l.], v. 11, n. 1, p. 706-715, 2011. DOI:10.1016/j.asoc.2009.12.032

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

NASSIF, A. B. Short term power demand prediction using stochastic gradient boosting. In: INTERNATIONAL CONFERENCE ON ELECTRONIC DEVICES, SYSTEMS AND APPLICATIONS (ICEDSA), 5th, 2016, [s. l.]. **Proceedings** [...] [S. l.: s. n.], 2016. p. 1-4. DOI:10.1109/icedsa.2016.7818510

NOSE-FILHO, K. **Previsão de carga multinodal utilizando redes neurais de regressão generalizada**. 2011. 90 f. Dissertação (Mestrado em Engenharia Elétrica) - Departamento de Engenharia Elétrica, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2011.

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

PANAPAKIDIS, I. P. Application of hybrid computational intelligence models in short-term bus load forecasting. **Expert Systems with Applications**, New York, v. 54, p. 105-120, 2016.

PYNE, R. A. Short-term bus load forecasting and its intended use in scheduled outage analysis. **IEEE Conference on Decision and Control**, New York, v. 13, p. 593-597, 1974.

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

PARLOS, A. G. *et al.* Development of an intelligent long-term electric load forecasting system. **Proceedings of International Conference on Intelligent System Application to Power Systems**, Orlando, FL, USA, p. 288-292, 1996. DOI: 10.1109/ISAP.1996.501084

PENYA, Y. K. et al. Short-term load forecasting in air-conditioned non-residential Buildings. In: INDUSTRIAL ELECTRONICS (ISIE), IEEE INTERNATIONAL SYMPOSIUM ON. GDANSK, 2011, Poland. **Proceedings** [...] Piscataway: IEEE, 2011. p. 1359-1364.

RANAWEERA K. D.; KARADY G. G.; FARNER G. R. Economic impact Analysis of Load Forecasting, **IEEE Transactions on Power Systems**, New York, v. 12, n. 3, p. 1388-1392, 1997.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, Washington, v. 65, p. 386-408, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation, in Rumelhart, D. E., and McClelland, J. L. (eds.), **Parallel Distributed Processing: Explorations in the Microstructure of Cognition I**, p. 318-362, MIT Press, Cambridge MA, 1986.

SINGH, V. P.; VAIBHAV, K.; CHATURVEDI, D. K. Load forecasting of DEI 33 kV substations using artificial neural network approach. *In: SUSTAINABLE FUTURE ENERGY; SEE FORUM*, 10th., 2012, Brunei Darussalam. **Proceedings [...]** Brunei Darussalam: [s. n.] 2012. p. 1-8.

SFETSOS, A. Short-term load forecasting with a hybrid clustering algorithm. **IEEE Proceedings Generation, Transmission, and Distribution**, New York, v. 150, n. 3, p. 257-262, 2003. DOI: 10.1049/ip-gtd:20030200.

STORB, B. H.; WAZLAWICK, R. S. **Algumas ‘pinceladas’ sobre redes neurais artificiais**. Departamento de Informática e Estatística – Universidade Federal de Santa Catarina - UFSC, 1999.

SRINIVASAN, D.; TAN, S. S.; CHANG, C. S. and CHAN, E. K. Practical implementation of a hybrid fuzzy neural network for one-day-ahead load 129 forecasting. **IEEE Proceedings Generation, Transmission, and Distribution**, New York, v. 145, n. 6, p. 687-692, 1998.

SALGADO, R. M.; OHISHI, T.; BALLINI, R. A short-term bus load forecasting system. **International Journal of Computer Information Systems and Industrial Management Applications**, New York, v. 3, p. 336-346, 2011.

SHERRY, L. Issues in distance learning. **International Journal of Educational Telecommunications**, New York, v.1, p. 337-365, 1996.

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.

SHAHIDEHPOUR, M.; YAMIN, H.; LI, Z. **Market operations in electric power systems: forecasting, scheduling, and risk management**. JohnWiley & Sons: Hoboken, 2003.

STORB, B. H.; WAZLAWICK, R. S. **Algumas pinceladas sobre redes neurais artificiais**. Florianópolis: Departamento de Informática e Estatística, Universidade Federal de Santa Catarina - UFSC, 1999.

SULLIVAN, R. L. **Power system planning**. New York: McGraw-Hill Inc, 1977.

SANTOS JÚNIOR, C. R. D. **Uma nova abordagem de treinamento online para rede neural artificial ARTMAP Fuzzy**. 2017. 57 f. Tese (Doutorado em Engenharia) - Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista, Ilha Solteira, 2017.

WU, L.; YUAN, J. S.; ZHU, Y. L. Mis-based long term distribution load forecasting system. Sixth International Conference on Advances in Power System Control, Operation and Management ASDCOM, 6., 2003, [s. l.]. **Proceedings [...]** [S. l.: s. n.], 2003. v. 2, p. 880-883. Doi: 10.1049/cp:20030703.

WASSERMAN, P. D. **Neural computing - theory and practice**. Van Nostrand Reinhold, 1989.

YAAKOB, S. N.; LIM, C. P.; JAIN, L. A novel euclidean quality threshold ARTMAP network and its application to pattern classification. **Neural Computing and Applications**. London, n.19, p. 227-236, 2010.

ZHENG, H.; YUAN, J.; CHEN, L. Short-term load forecasting using EMD-LSTM neural networks with a xgboost algorithm for feature importance evaluation. **Energies**, Paris, v. 10, n. 8, p. 1-20, 2017.

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

APÊNDICE A – DADOS DE CARGAS

Este apêndice apresenta os dados históricos de cargas elétricas fornecidas pela *Electricity Comission* utilizados neste trabalho como carga real, bem como as cargas previstas obtidas por meio da metodologia proposta nesta pesquisa. Foram considerados 15 dias de dados compreendidos no período entre 15 e 29 de outubro do ano de 2007, cujas cargas foram medidas a cada meia hora totalizando 750 padrões de entrada.

Tabela A.1 – Carga global real e prevista.

Carga Real	Carga Prevista
174192	173107,20
166588	166273,63
161594	161992,36
158736	158636,35
156068	156334,97
154508	153469,03
152910	151048,07
153422	150934,38
156050	152320,30
164348	164163,93
184288	184102,46
213216	212893,87
243918	242521,02
276580	275101,01
303620	302895,94
316372	317396,20
318832	318550,81
311260	313040,44
303124	306604,81
292280	295552,70
280260	286180,56
271458	276437,93
268480	269716,10
264066	267759,73
260022	262006,28
257178	257832,83
253672	253863,25
249054	249091,90
248966	248078,43
249112	246592,54
260640	255466,76
276368	274718,76

285676	279729,25
289958	289940,40
293808	292753,41
293478	294011,92
288012	290930,34
279012	278578,01
272410	271837,13
267548	269672,97
280072	278582,48
279648	278984,34
264256	264405,68
249210	249789,77
231440	232251,07
213764	214075,27
198362	197195,23
183520	183216,41

Fonte: Resultados da pesquisa.

Tabela A.2 – Cargas reais por subestação.

<i>Sub 1</i>	<i>Sub 2</i>	<i>Sub 3</i>	<i>Sub 4</i>	<i>Sub 5</i>	<i>Sub6</i>	<i>Sub7</i>	<i>Sub8</i>	<i>Sub9</i>
17074	15598	32076	32076	42810	18232	11424	18310	7254
16430	15110	31524	31524	41034	17516	10688	17238	6314
15844	14680	30940	30940	39804	17008	10382	16836	5634
15236	14508	31116	31116	38658	17136	10076	16308	5490
15008	14250	30334	30334	37914	17168	9960	16108	5414
14936	14182	30506	30506	37426	16492	9840	16108	5328
13874	14306	30284	30284	37254	16738	9922	15724	5270
13958	14518	30928	30928	36968	16644	9730	15974	5194
14340	14594	31366	31366	37570	16946	10206	16154	5260
15366	15052	33002	33002	39002	17898	11426	17190	5500
17014	15856	37908	37908	42380	18906	14338	21048	6276
20418	17022	43558	43558	47620	21208	18782	25394	7340
24012	18522	48714	48714	55638	23056	22600	29022	9092
27380	20424	50914	50914	66664	25930	25080	33408	10462
30784	23244	50794	50794	78518	29490	26768	33334	11096
32886	25042	50222	50222	84762	29642	26482	33430	12522
33292	25148	50674	50674	85534	29412	26544	33488	13098
32182	24774	50544	50544	82872	29316	24682	33330	12800
30700	23820	50494	50494	80696	29214	22676	33640	12254
29352	22988	49340	49340	79148	27316	20406	33148	11698
28610	21936	47266	47266	76714	26110	18932	31124	11000
27512	20626	45610	45610	75512	25078	18314	30444	10406
27214	21296	45430	45430	74968	24174	17964	29696	9984
25314	21362	44736	44736	74738	24134	17468	29208	9514

24932	21736	43932	43932	73966	23412	17128	28108	9294
25650	21324	43194	43194	73020	23198	16432	28270	9044
25482	20532	42354	42354	72878	23236	16200	27610	8910
24850	19308	42304	42304	72276	23228	16060	26078	8662
24014	19680	42362	42362	72134	23140	15978	27188	8584
24084	19556	42104	42104	72248	23036	16112	27380	8700
25254	21048	44922	44922	73164	23752	17866	29526	8968
26772	22310	48708	48708	74940	24736	21086	31736	9658
26820	23362	49196	49196	76628	24936	22852	33632	11200
27704	23792	50272	50272	78032	24840	23698	33268	10722
28826	23858	50258	50258	78976	25166	24152	33776	10492
29364	24632	49598	49598	78032	26158	23384	32896	10454
29398	24350	47446	47446	76800	26236	22746	31640	10224
28590	22702	45366	45366	74968	26022	22466	30070	9830
28608	22314	42620	42620	73622	25786	21686	29262	9696
28142	22070	40654	40654	73508	25858	20650	28124	9696
29338	22940	40562	40562	77974	27072	21346	29980	10358
29148	22816	39708	39708	78346	27318	21556	29934	10310
26556	21966	37806	37806	74166	26056	19876	28196	9840
25112	20886	36674	36674	69728	24596	17960	26774	9132
23642	19576	35432	35432	63486	23262	16124	24816	8402
22102	18266	34342	34342	57500	21478	14384	23020	7656
20108	17036	34048	34048	51516	20350	12688	21958	7080
17374	16038	33626	33626	46362	19224	11572	20608	6458

Fonte: (CDS, 2010)

Tabela A.3 – Cargas previstas por subestação.

<i>Sub 1</i>	<i>Sub 2</i>	<i>Sub 3</i>	<i>Sub 4</i>	<i>Sub 5</i>	<i>Sub6</i>	<i>Sub7</i>	<i>Sub8</i>	<i>Sub9</i>
17251,888	15793,28	32502,65	11433,49	42280,01	18228,90	11424,00	18286,93	6871,63
16586,698	14984,73	31659,85	10685,7	41545,22	17569,01	10590,95	17865,46	6098,65
16107,371	14579,47	31322,73	10283,5	40018,36	17021,11	9794,83	17328,14	5535,96
15313,056	14345,36	30858,21	10086,31	38572,03	17131,09	10034,26	16505,18	5399,55
15230,885	14278,48	30999,33	9778	38914,20	16997,11	9910,56	16353,37	5571,95
14904,16	14298,15	29805,69	9760,248	37132,54	16347,22	9826,75	16650,99	5255,56
14086,368	14128,96	30342,73	9740,723	36707,86	16211,24	10369,47	16496,00	5138,10
13945,504	14589,31	30378,01	9572,813	36792,80	17165,08	9766,90	15832,03	5236,61
14260,491	15425,40	30897,41	9637,244	36822,42	16815,14	9766,90	15832,03	5100,20
15125,238	15944,76	32896,61	9693,865	38801,61	17475,03	11277,32	17210,29	5418,49
16913,424	15944,76	37198,80	10273,74	42222,73	18664,83	14555,57	21021,48	6335,47
20114,16	17504,81	42729,92	11451,06	47285,27	20830,46	18558,10	25286,10	7350,96
23559,45	18295,65	47582,87	13378	54836,61	22688,14	21776,49	29015,39	8830,63
27129,956	20194,07	50295,51	16060,77	66263,38	26259,54	25292,17	32778,65	9857,49
30007,877	22865,63	49913,31	18938,67	78140,49	29492,99	26878,42	33455,79	10628,58
32402,559	25206,69	50003,47	21322,6	84277,57	29444,99	26317,99	33188,13	11744,49

32519,946	24935,20	49911,35	21275,74	84899,77	29359,01	26472,00	33497,74	12290,13
32075,834	24472,89	49076,39	20809,11	82723,05	29564,97	24813,30	33158,17	12687,99
30743,498	23863,04	50264,15	20089,97	81336,43	29716,00	22748,19	33372,00	12651,99
29360,295	22743,66	49013,67	19032,39	79894,51	26939,42	20180,26	33128,21	12271,18
28853,577	22057,08	48374,71	19032,39	77263,49	24949,76	18977,11	33372,00	11617,55
27486,026	21012,46	45460,19	18313,89	75566,76	25126,00	18665,84	30633,35	10391,76
27345,162	21567,23	43165,04	18013,21	75454,17	24509,83	18749,65	30317,75	9793,07
25826,964	21860,35	42392,80	17499,72	74097,18	24207,88	17458,70	29754,46	9584,67
26656,495	21830,84	42392,80	17003,8	73785,09	23688,00	17386,87	28865,58	9493,73
25603,93	21342,96	41161,92	16710,02	72964,02	23216,05	16618,69	27944,00	9076,92
25171,557	20910,16	42828,00	16668	72764,05	23546,00	16530,89	26922,04	9129,97
24821,354	19385,52	40846,36	16078,34	72233,96	23693,97	15912,36	26528,53	8586,23
25827,977	19875,37	40846,36	16162,3	71395,05	23436,00	15884,42	25413,94	8286,88
24400,72	19997,34	40846,36	15939,72	70956,55	23436,00	16395,22	27850,00	8531,29
25171,557	20758,68	40607,24	16013,91	73445,35	23693,97	18871,36	27850,00	9285,33
26942,135	22216,43	46900,79	16218,92	75057,14	24589,82	20880,61	31895,76	9675,61
27041,914	23223,67	49821,19	16677,74	76670,92	24589,82	22554,65	32968,41	10645,63
27998,613	24083,37	49705,55	17519,24	78282,71	24425,85	23713,90	33274,02	11744,49
28851,621	24945,04	49680,07	18013,21	78932,57	24425,85	24434,20	33558,00	10401,23
28910,314	24323,38	47933,71	18593,09	78304,08	25621,64	23851,58	33210,00	9347,85
28898,575	24522,08	46602,87	19276,44	77376,08	26197,55	23145,25	32475,03	9184,91
28393,814	22912,84	45064,27	18985,53	76104,02	25639,64	22123,66	30443,59	9493,73
28370,336	22499,72	43517,84	18472,03	77374,03	26359,52	21030,25	29790,42	9802,55
28429,03	21952,82	41042,36	19239,34	74407,29	26477,50	20788,82	28539,99	9857,49
28920,096	22358,07	40691,52	20781,77	73530,28	26477,50	21624,00	28010,66	9857,49
28837,926	23562,05	39525,32	20658,77	77460,01	27309,36	21463,23	28298,30	10683,53
26421,722	24370,60	37886,76	19715,74	76273,89	27309,36	19986,72	29033,37	10410,71
25568,714	21407,88	36454,00	18481,8	68779,83	24889,77	18270,78	27527,27	9076,92
23582,928	20538,34	35213,32	16798,79	62275,37	24889,77	16243,57	25939,28	9431,21
21853,435	18285,82	34315,64	15266,13	57835,03	21996,26	14415,90	23124,83	7269,50
20102,421	18069,42	33300,37	13405,45	51923,13	21482,35	12949,37	22397,74	7451,38
17952,293	16121,81	32532,05	12181,27	47229,96	19298,72	11642,46	20799,76	6725,99

Fonte: Resultados da pesquisa.

Tabela A.4 – Carga global real e carga global prevista pela soma das subestações.

Carga Real	Soma Global
174192	174072,78
166588	167586,27
161594	161991,46
158736	158245,04
156068	158033,88
154508	153981,31
152910	153221,46
153422	153279,05

156050	154557,23
164348	163843,21
184288	183130,80
213216	211110,83
243918	239963,24
276580	274131,53
303620	300321,76
316372	313908,49
318832	315160,88
311260	309381,71
303124	304785,26
292280	292563,59
280260	284497,66
271458	272656,28
268480	268915,11
264066	262682,73
260022	261103,21
257178	254638,51
253672	254470,66
249054	248086,62
248966	247128,30
249112	248353,19
260640	255697,39
276368	274377,22
285676	284193,94
289958	290747,75
293808	293241,79
293478	290095,64
288012	287678,78
279012	279161,11
272410	277216,68
267548	270734,64
280072	272251,39
279648	277798,48
264256	271408,87
249210	250456,97
231440	234912,58
213764	214362,53
198362	201081,62
183520	184484,31

Fonte: Resultados da pesquisa.