

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

TANIA TENÓRIO GOMES

**PREVISÃO DE CARGAS MULTINODAIS COM O USO DE REDE NEURAL
ARTMAP MANHATTAN**

Ilha Solteira
2022

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

TANIA TENÓRIO GOMES

**PREVISÃO DE CARGAS MULTINODAIS COM O USO DE REDE NEURAL
ARTMAP MANHATTAN**

Tese apresentada à Faculdade de Engenharia de
Ilha Solteira – Unesp como parte dos requisitos
para obtenção do título de Doutora em
Engenharia Elétrica.
Especialidade: Automação

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

FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

G633p Gomes, Tania Tenório.
Previsão de cargas multinodais com o uso de rede neural ARTMAP
Manhattan / Tania Tenório Gomes. -- Ilha Solteira: [s.n.], 2022
112 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia
de Ilha Solteira. Área de conhecimento: Automação, 2022

Orientador: Mara Lúcia Martins Lopes
Inclui bibliografia

1. Previsão de cargas multinodais e nodais. 2. Distância Euclidiana. 3.
Distância de Manhattan. 4. Teoria da Ressonância Adaptativa. 5. Rede
ARTMAPEuclidiana. 6. Treinamento Reverso e Direto.


Raiane da Silva Santos
Supervisora Técnica de Seção
Seção Técnica de Referência, Atendimento ao usuário e Documentação
Diretoria Técnica de Biblioteca e Documentação
CRB 8 - 9999



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Ilha Solteira

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Previsão de Cargas Multicargas com o Uso de Rede Neural ANTMAP Manhattan

AUTORA: TANIA TENÓRIO GOMES

ORIENTADORA: MARA LUCIA MARTINS LOPES

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

Prof. Dr. MARA LUCIA MARTINS LOPES (Participação Presencial)
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. CARLOS ROBERTO MINUSSI (Participação Presencial)
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Profa. Dra. LILIAN YULI ISODA (Participação Presencial)
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira

Profa. Dra. THAYS APARECIDA DE ABREU SANTOS (Participação Virtual)
Departamento de Engenharia Elétrica e Computação / Medical Image Computing Lab (MICLab), Unesp

Prof. Dr. JOSÉ GUI HERME MAGALINI SANTOS DECANINI (Participação Virtual)
Departamento de Eletrotécnica / Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - IFSP

Ilha Solteira, 02 de maio de 2022

DEDICATÓRIA

Yeshua

AGRADECIMENTOS

Agradeço a Deus por todos esses dias de aprendizado e pelo seu eterno amor e cuidado.

Aos meus pais Leonice e Otacílio (in memorian), pela vida.

Aos meus filhos, Lorena, Nicole e David, meus amados frutos, meus irmãos Odenir e Cilin, Nilton, e toda família.

A minha orientadora Dr^a. Mara Lúcia pela oportunidade desse trabalho.

Aos queridos professores Dr. Carlos Roberto Minussi e Dr^a. Anna Diva Plascencia Lotufo, pelos ensinamentos e conselhos.

Aos meus amigos de laboratório, Monara, Marleíde, Marcos Ricardo, Júnior, Thays, Aline, Douglas, Haislan, Nayara, Joaquim, Andreia Brasil, Priscila, Tatiana, Ronald, Salvador, Leonardo, Danielli, Giovanny, Drieli, Camila, Paula, Anthony, Andreia e Seyed Farhad.

Aos técnicos Deoclécio e Rafael.

Aos professores do departamento da Engenharia Elétrica.

A UNESP e todos os profissionais desta nobre instituição.

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

“Os jovens se cansam e se fatigam, e os moços de exautos caem, mas os que esperam no Senhor renovam as tuas forças, sobem com asas como águias, correm e não se cansam, caminham e não se fatigam”.

Isaías 40:30-31.

RESUMO

A eficiência e a qualidade da energia elétrica sempre foram sinônimos de crescimento e desenvolvimento em qualquer sociedade. Assim, essa energia fortalece uma nação em seus aspectos tecnológicos, social e econômico. Soluções provisórias na operação como sistema de implantação e mudança na estrutura do sistema de rede como, por exemplo, de barramentos são medidas de execução para ampliação da demanda de energia. É neste contexto que as Empresas Elétricas apresentam uma contribuição em uma ação de sistemas de interligações regionais. Para remediar essa energia é imprescindível o planejamento, investimento e as propostas suprindo a falta de energia. Na literatura há poucas informações relacionadas a previsão de cargas elétricas multinodais. Esse sistema beneficia diferentes níveis de sistemas, por exemplo, o barramento. Artigos publicados com excelentes resultados têm exposto a previsão de cargas elétricas a curto prazo para tomadas de decisões e, entre as técnicas de previsão proeminente, as redes neurais artificiais têm apresentado respostas significativas em relação a sua capacidade relevante e velocidade no aprendizado. Neste trabalho é proposto duas metodologias: um estudo para previsão de cargas multinodais, utilizando uma das redes neurais da família da Teoria da Ressonância Adaptativa, intitulada ARTMAP Euclidiana com Treinamento Reverso, sendo uma nova formulação e inovação para treinamento da rede, e com o mesmo banco de dados históricos desta pesquisa inseriu-se uma nova estratégia a fim de favorecer o melhor neurônio vencedor por meio da clusterização na operação com o uso da equação da distância de Manhattan, batizada com o nome de ARTMAP Manhattan, uma rede equivalente a arquitetura da rede neural ARTMAP Euclidiana visando a melhoria nas previsões multinodais em Treinamento Direto. As medidas de desempenho utilizadas para avaliar as propostas deste trabalho foram MAPE, Erro Máximo, Erro Mínimo, MAE, RMSE. Com base nas análises gráficas e nas medidas de desempenho, tem-se que a rede neural ARTMAP Euclidiana com Treinamento Reverso tem aproveitamento aceitável e a rede neural ARTMAP Manhattan atinge resultados eficientes em relação ao Treinamento Direto para as previsões de cargas nodais.

Palavras-chave: Previsão de cargas elétricas multinodais e nodais; Distância Euclidiana; Distância de Manhattan; Teoria da Ressonância Adaptativa; Rede ARTMAP Euclidiana; Treinamento Reverso e Direto.

ABSTRACT

The efficiency and quality of electric energy have always been synonymous with growth and development in any society, so this energy strengthens a nation in its technological, social, and economic aspects. Temporary solutions in the operation as an implementation system and changes in the structure of the network system such as implementations are measures of execution to increase the energy demand. It is in this context that the Electric Companies present a contribution to the action of regional interconnection systems. To remedy this energy planning, investment, and proposals to supply the energy shortage are essential. In the literature there is not much information related to the prediction of multinodal electrical loads, this system benefits different levels of systems, for example, the bus. Published articles with excellent results have exposed the short-term prediction of electrical charges necessary for decision making among the prominent prediction techniques, artificial neural networks have presented significant answers regarding their relevant capacity and speed in learning. In this survey, two methodologies are proposed: a study to predict multinodal loads, using one of the neural networks of the Adaptive Resonance Theory family entitled ARTMAP Euclidean with Reverse Training, with the new formulation and innovation for training data during simulations and with the same historical database of this research, a new strategy was inserted in order to favor the best winning neuron through clustering in the operation of the Manhattan distance equation, baptized with the name of ARTMAP Manhattan, a network equivalent to the architecture of the ARTMAP Euclidean neural network aiming to improve multinodal predictions in Direct Training. The performance measures to evaluate the proposals of this work were MAPE, Maximum Error, Minimum Error, MAE, RMSE, and the graphs show that the methodology of the ARTMAP Euclidean neural network with Reverse Training has acceptable use and the ARTMAP Manhattan neural network achieves efficient results compared to Direct Training for nodal loads predictions.

Keywords: Forecasting multinodal and nodal electrical loads; Euclidean Distance; Manhattan Distance; Adaptive Resonance Theory; ARTMAP Euclidean Network; Reverse and Forward Training.

LISTA DE FIGURAS

Figura 1	- Diversidade do Setor Elétrico.....	27
Figura 2	- PIB Trimestral Realizado (T/t-4) x Incerteza (FGV).....	28
Figura 3	- Classificação dos Períodos das Previsões.....	29
Figura 4	- Ilustração Carga Elétrica Global	31
Figura 5	- Representação Simbólica Carga Elétrica Multinodal.....	32
Figura 6	- Sistema Previsional Multinodal	33
Figura 7	- Localização Geográfica das Subestações.....	35
Figura 8	- Perfil das Cargas Elétricas das Subestações.....	36
Figura 9	- Representação Distinta das Janelas.....	40
Figura 10	- Estrutura dos Dados para Simulação.....	41
Figura 11	- EstruturaARTMAP Euclidiana.....	43
Figura 12	- Vetores Entrada, Módulo ART_a	43
Figura 13	- Vetores Saída, Módulo ART_b	44
Figura 14	- Vetores Entrada, Módulo ART_a , para Treinamento Reverso.....	44
Figura 15	- Vetores Saída, Módulo ART_b , para Treinamento Reverso.....	44
Figura 16	- Fluxograma ARTMAP Euclidiana com Treinamento Reverso.....	50
Figura 17	- Estrutura da Previsão Local com Treinamento Reverso.....	51
Figura 18	- Mapa das Ruas Quadriculadas da Ilha de Manhattan.....	52
Figura 19	- Geometria Urbanano Espaço Euclidiano.....	53
Figura 20	- Camada de Reconhecimento (F_2).....	55
Figura 21	- Representação do Processo da Previsão.....	56
Figura 22	- Fluxograma ARTMAP Manhattan.....	60
Figura 23	- Representação Gráfica do Resultado da Previsão Global.....	65
Figura 24	- Conjunto de Gráficos das Previsões Multinodais.....	67
Figura 25	- Representação Gráfica da Previsão Global.de Manhattan.....	73
Figura 26	- Previsão da Subestação Kopu.....	75
Figura 27	- Previsão da Subestação Cambridge.....	75
Figura 28	- Previsão da Subestação Hamilton 11kV.....	76
Figura 29	- Previsão da Subestação Hamilton 33kV.....	76
Figura 30	- Previsão da Subestação Hinuera.....	77
Figura 31	- Previsão da Subestação Waihou.....	77

Figura 32	- Previsão da Subestação Waikino.....	78
Figura 33	- Previsão da Subestação Te Awamutu.....	78
Figura 34	- Previsão da Subestação Kinleith.....	79
Figura 35	- Representação Geométrica da Categoria Elipsoidal Comparada com Categoria do Hiper-retângulo.....	92
Figura 36	- Comparação entre as Geometrias da Categorias em Hiper-retângulos e Hiper-esferas.....	93
Figura 37	- Fluxograma da Rede ARTMAP Euclidiana.....	97
Figura 38	- Surgimento da Principais Redes da Família ART.....	99
Figura 39	- Modelo da ART1.....	100
Figura 40	- Subsistema de Atenção e Orientação.....	101
Figura 41	- Representação Geométrica da Rede ART.....	102
Figura 42	- Rede Neural ART <i>Fuzzy</i>	104
Figura 43	- Rede Neural ARTMAP.....	107
Figura 44	- Fluxograma da Rede Neural ARTMAP <i>Fuzzy</i>	108

LISTA DE TABELAS

Tabela 1	- Equações Utilizadas no Treinamento das Redes.....	55
Tabela 2	- Dados Coletados	61
Tabela 3	- Métricas Utilizadas na Análise de Desempenho da Metodologia	63
Tabela 4	- Parâmetros da Rede Neural ARTMAP Euclidiana.....	64
Tabela 5	- Métricas Obtidas para o Sistema Previsor Global.....	64
Tabela 6	- Parâmetros da ARTMAP Euclidiana com Treinamento Reverso.....	66
Tabela 7	- Métricas Obtidas para o Sistema Previsor Local.....	66
Tabela 8	- Parâmetros Utilizado na Rede ARTMAP de Manhattan.....	72
Tabela 9	- Métricas Obtidas para o Sistema Previsor Global com ARTMAP Manhattan	72
Tabela 10	- Valores dos Parâmetros da ARTMAP de Manhattan.....	74
Tabela 11	- Métricas Obtidas Utilizando a Rede ARTMAP Manhattan	74

LISTA DE QUADROS

Quadro 1	- Característica das Subestações.....	36
Quadro 2	- Representação dos Dados Exógenos.....	38
Quadro 3	- Dados Exógenos das Cargas Elétricas	39
Quadro 4	- Cargas Elétricas em Janelamento.....	39
Quadro 5	- Cálculo Euclidiano e NãoEuclidiano.....	53
Quadro 6	- Geometria Euclidiana e NãoEuclidiana.....	54
Quadro 7	- Dados Originais.....	62
Quadro 8	- Dados para Treinamento.....	62
Quadro 9	- Código da Escolha da Categoria.....	90

LISTA DE SIGLAS E ABREVIATURAS

ARIMA	<i>AutoRegressive Integrated Moving Average.</i>
ART	<i>Adaptive Resonance Theory.</i>
ARTMAP	<i>Adaptive Resonance Theory –Supervised Predictive Mapping.</i>
CNN	Redes Neurais de Convolução.
EPE	Empresa de Pesquisa Energética.
FAM-AI	ArtMap Fuzzy com Área de Influência.
FCRBM	<i>Factored Conditional Restricted Boltzmann Machine.</i>
GPR	Regressão de Processo Gaussiano.
GWDO	<i>Genetic Wind Driven Optimization.</i>
LDF	Fator de Distribuição de Carga.
LSTM	<i>Long Short-Term Memory.</i>
MAE	<i>Mean Absolute Error.</i>
MAPE	<i>Mean Absolute Percentage Error.</i>
MLP	<i>Multi Layer Perceptron.</i>
MI-ANN	Rede Neural de Informação Mútua.
MMI	<i>Modified Mutual Information Technique.</i>
RBFNN	Rede Neural de Função de Base Radial.
RMSE	<i>Root Mean Sqauare Error.</i>
RNA	Rede Neural Artificial.
SARIMA	<i>Seasonal Auto Regressive Integrated Moving Average.</i>
SD	<i>Similar Day.</i>
SPC	<i>Control Statistc Process.</i>
SVR	<i>Support Vector Regression.</i>
TW	Transformada Wavelet.

LISTA DE SÍMBOLOS

I^a	Vetor de entrada da camada F_0 do módulo ART_a .
I^b	Vetor de entrada da camada F_0 do módulo ART_b .
w_{ij}	Matriz de pesos.
w^a	Vetor pesos do módulo ART_a .
w^b	Vetor pesos do módulo ART_b .
w^{ba}	Matriz de pesos do módulo <i>Inter</i> – <i>ART</i> do Treinamento Reverso.
w^{ab}	Matriz de pesos do módulo <i>Inter</i> – <i>ART</i> .
M	Número de neurônio da camada F_0 .
N	Número de neurônio da camada F_2 .
ρ_a	Parâmetro de vigilância do módulo ART_a .
ρ_b	Parâmetro de vigilância do módulo ART_b .
ρ_{ba}	Parâmetro de vigilância do módulo <i>Inter</i> – <i>ART</i> do Treinamento Reverso.
ρ_{ab}	Parâmetro de vigilância do módulo <i>Inter</i> – <i>ART</i> .
β	Taxa de treinamento.
ε	Valor do decremento do treinamento global (clássico).
J	Índice da categoria ativa da camada F_2 do módulo ART_a .
K	Índice da categoria ativa da camada F_2 do módulo ART_b .
T_j^a	Função de escolha do módulo ART_a .
T_k^b	Função de escolhido módulo ART_b .
x^a	Vetor atividade da camanda F_1 do módulo ART_a .
x^b	Vetor atividade da camanda F_1 do módulo ART_b .
x^{ba}	Vetor atividade do módulo <i>Inter</i> – <i>ART</i> do Treinamento Reverso.
x^{ab}	Vetor atividade do módulo <i>Inter</i> – <i>ART</i> .
y_j^a	Vetor atividade da camanda F_2 do módulo ART_a .
y_k^b	Vetor atividade da camanda F_2 do módulo ART_b .
F_0	Camada de entrada.
F_1	Camada de comparação.
F_2	Camada de reconhecimento.

SUMÁRIO

1	INTRODUÇÃO.....	18
1.1	OBJETIVOS.....	19
1.2	ORGANIZAÇÃO DO TEXTO.....	20
2	REVISÃO BIBLIOGRÁFICA.....	21
3	PREVISÃO DE CARGAS ELÉTRICAS MULTINODAIS.....	27
3.1	FATORES QUE INFLUENCIAM A PREVISÃO.....	28
3.2	HORIZONTE DE PREVISÃO.....	29
3.3	TÉCNICAS DE PREVISÃO.....	30
3.4	SISTEMA PREVISOR MULTINODAL.....	31
4	CARACTERÍSTICAS PARTICULARES DAS SUBESTAÇÕES.....	35
5	DESCRIÇÃO DOS DADOS.....	38
6	REDE NEURAL ARTMAP EUCLIDIANA.....	42
7	REDES NEURAIS APLICADAS NA PREVISÃO DE CARGAS ELÉTRICAS	
		45
7.1	ARTMAP EUCLIDIANA COM TREINAMENTO REVERSO.....	45
7.2	ARTMAP MANHATTAN.....	51
8	RESULTADOS.....	61
8.1	RESULTADO DA PREVISÃO GLOBAL.....	63
8.2	RESULTADOS DAS PREVISÕES MULTINODAIS COM TREINAMENTO REVERSO.....	65
8.3	RESULTADO DA PREVISÃO GLOBAL – ARTMAP MANHATTAN.....	71
8.4	RESULTADOS DAS PREVISÕES NODAIS – ARTMAP MANHATTAN.....	73

9	CONCLUSÃO E SUGESTÕES PARA PESQUISAS FUTURAS.....	80
9.1	CONCLUSÃO.....	80
9.2	SUGESTÕES PARA PESQUISAS FUTURAS.....	81
	REFERÊNCIAS.....	83
	APÊNDICE A – Código da Função Escolha da Categoria.....	90
	ANEXO A – Rede Neural ARTMAP Euclidiana.....	91
	ANEXO B – Teoria da Ressonância Adaptativa.....	98

1 INTRODUÇÃO

Acrescente demanda de energia elétrica requer que as concessionárias e empresas do setor elétrico obtenham planejamento e esquema dinâmico no fornecimento de energia para consumo das fábricas, indústrias e da população em geral. Deste modo, torna-se necessário projetos e estudos que assegurem um resultado eminente na previsão das cargas elétricas. A credibilidade para previsão de carga se faz relevante para tomada de decisões para sistema operacional, essencial para segurança, qualidade e flutuações nos distúrbios de tensões na distribuição (LOPES, 2005).

Existem fatores que podem influenciar o comportamento da carga elétrica, tais como mudança climática, feriados, dias atípicos e incidência solar (GROSS; GALIANA, 1987; KHATOONet *al.*, 2014). As pesquisas relacionadas as técnicas de previsões tradicionalmente utilizadas são baseadas em métodos estatísticos ou estocásticos, como a Regressão Linear Simples ou Múltipla, Alisamento Exponencial, Espaço de Estado e Filtro de Kalman, Série Temporal de Box & Jenkins (BOX; JENKINS, 1976; O'DONOVAN, 1983). A recente pesquisa realiza previsão de cargas multinodais e nodais, conhecida como previsão de carga por vários pontos do sistema elétrico (PYNE, 1974). Neste sentido, optou-se por uma abordagem de previsão global e local, com dados originais de nove subestações cedidos pela companhia energética de Nova Zelândia.

Os trabalhos de Quin (QUINet *al.*, 2021), de Li (LI Y.; ZHANG S.; HU R., LU N, 2021), de Andriopoulos (ANDRIOPOULOSet *al.*, 2020), de Hafeez (HAFEEZ, G.; ALIMGEER, K. S.; KHAM, I, 2020), de Liu (LIUet *al.*, 2019), de Sun (SUNet *al.*, 2021), de Sideratos (SIDERATOSet *al.*, 2019), de Shafiul (SHAFIUL *et al.*, 2021), de Santos (SANTOS, J. A. A.; CHAUCOSKI, Y., 2020, JARNDAL A.; HUSAIN S., em 2020) e de Takiar (TAKIAR *et. al.*, 2017) são pesquisas recentes que tem a finalidade de estimar a demanda de cargas elétricas de forma global.

Atualmente, as técnicas baseadas na inteligência artificial são bastantes difundidas nas áreas de humanas, biológicas e exatas pois auxiliam no processo de tomada de decisões. Dentre as metodologias existentes destacam-se: Computação Natural, Computação Evolutiva, Inteligência Coletiva, Sistema Imunológico Artificial, Lógica Fuzzy, entre outras, as Redes Neurais Artificiais. As Redes Neurais Artificiais (RNAs) são modelos matemáticos

que utilizam estruturas que imitam as cognições básicas de um neurônio biológico e se destacam pelos algoritmos capazes de aprender e armazenar informações (HAYKIN, 1999).

Nesta pesquisa, a rede ARTMAP Euclidiana foi utilizada por conceder o privilégio de uma estrutura que garante a estabilidade e a plasticidade (CARPENTER, GROSSBERG, 1992), características de aprender e armazenar as informações sem que se perca o conhecimento já adquirido. Este modelo dispõe de um procedimento auto-organizável, com treinamento supervisionado (exige o auxílio de um “professor”), utilizando vetores de entrada e indicando seus respectivos vetores “alvos” de saída. A primazia da rede neural ARTMAP Euclidiana está na não necessidade de realizar subterfúgios no banco de dados para os testes, sendo assim, os dados se mantêm originais, sem normalização e complementação (VUSKOVIC; DU, 2002).

1.1 OBJETIVOS

O objetivo desta pesquisa é realizar previsões de cargas elétricas multinodais em curto prazo, em vários pontos do sistema elétrico. Neste sentido, um banco de dados originais de um conjunto de nove subestações foi essencial para os testes visando um quadro de sistemas interligados. Para essa idealização a rede neural ARTMAP Euclidiana com treinamento reverso (AMORIM, *et al.*, 2020) usufruiu do método de fator de participação (ALTRAN, 2008), que é um procedimento no qual as informações contidas no banco de dados das subestações auxiliam em conjunto com os dados do ponto/barramento pretendido no treinamento, realizando a previsão almejada. E para sistemas isolados, o nascimento de uma nova proposta com uso de uma rede neural intitulada ARTMAP Manhattan foi desenvolvida para as previsões das subestações locais.

No momento atual, este trabalho dispõe de uma colaboração por atender dois tipos de situações distintas de previsões: a) uma com sistema previsor para cargas elétricas multinodais visando estimar a carga futura reunindo informações globais, e a outra, b) de sistema de previsão das cargas elétricas com informações peculiares das subestações.

Ressalta que o banco de dados mantém sem intermediários servindo para as simulações das referidas propostas utilizados em um esquema de dia da semana, horário e decargas elétricas em série temporal, este procedimento se torna importante visto que os pré-processamentos, filtros utilizados em dados originais podem gerar respostas não

condizentes com a realidade presente no local, fato é que fatores externos como dias atípicos podem interferir na avaliação de análise das previsões.

1.2 ORGANIZAÇÃO DO TEXTO

O presente trabalho está dividido em nove capítulos transcritos conforme os tópicos dos conteúdos:

- Capítulo 2: Revisão Bibliográfica: contempla as pesquisas relevantes relacionadas as previsões de cargas elétricas com uso de métodos baseados em redes neurais artificiais e metodologias híbridas e artigos que apresentam abordagens do uso da distância de Manhattan.
- Capítulo 3: Previsão de Cargas Elétricas: de forma genérica descreve os fatores que influenciam na previsão de cargas elétricas, o horizonte de previsão apresentando a classificação dos períodos relacionado ao tempo, métodos de técnicas de previsão normalmente empregados na literatura e a estrutura do Sistema Previsor Multinodal.
- Capítulo 4: Características particulares das Subestações: revela as propriedades comuns das nove subestações, particularidades da região e o perfil das demandas das cargas elétricas.
- Capítulo 5: Descrição dos dados: apresenta os dados históricos das subestações, dados exógenos e a posição do janelamento das cargas elétricas.
- Capítulo 6: Rede Neural ARTMAP Euclidiana: apresenta a estrutura e as principais características.
- Capítulo 7: Metodologias: especifica o uso da rede neural ARTMAP Euclidiana com Treinamento Reverso para resolução de previsão de cargas e a recente rede neural ARTMAP Manhattan que é uma nova estrutura neural utilizada na previsão em pontos isolados.
- Capítulo 8: Resultados: apresentam as previsões de cargas elétricas multinodais e nodais por meio das métricas e dos gráficos das curvas de demandas obtidas.

- Capítulo 9: Conclusão:finalizando a proposta da pesquisa relata nitidamente a repercussão das metodologias utilizadas para previsão de cargas elétricas a curto prazo.

2 REVISÃO BIBLIOGRÁFICA

A literatura especializada dispõe de inúmeras pesquisas e uma série de alternativas para o uso de métodos eficientes na abordagem do problema de previsão de cargas elétricas. As técnicas de previsão de cargas elétricas que obtiveram ênfase em pesquisas são: técnica de regressão linear simples ou múltipla, alisamento exponencial, estimação de estado, filtro de *Kalman*, *ARIMA* (*Auto Regressive Integrated Moving Average*) de *Box* e *Jenkins* (*BOX* e *JENKINS*, 1976). Nos dias atuais, as técnicas inteligentes tem fornecido resultados precisos, também, o uso de modelos híbridos.

Apresentam-se neste capítulo, algumas publicações relacionadas as previsões de cargas elétricas que utilizam redes neurais artificiais e trabalhos que abordam o tratamento e utilização da distância de Manhattan.

Qin et al., em 2021, descreveram a importância do sistema de transmissão de potência, e com o desenvolvimento das redes inteligentes, a geração de energia renovável e o futuro do mercado de energia, a previsão de carga se torna cada vez mais importante para o despacho de energia e a garantia da operação estável. Neste trabalho, eles fizeram a previsão de cargas reativas e ativas a curto prazo (um mês, uma semana e um dia). Utilizaram informações de cinco subestações. A proposta foi realizada em três etapas: (1) o uso dos dados de cargas históricas e fatores externos (temperatura, clima, umidade etc.) para construção de dados de entrada, (2) logo após, o uso dos dados brutos no pré processamento para filtrar e remover os *outliers* e (3) por fim, os dados são utilizados no modelo de previsão de cargas.

Os autores *Liet al.*, em 2021, relataram a limitação do desenvolvimento de modelos automatizados, confiáveis e robustos para a previsão de cargas. Eles exploraram a identificação do melhor modelo de previsão de distribuição de energia por técnicas de aprendizagem e desenvolveram uma metodologia de modelo com uso de uma estrutura de meta-aprendizado. A estrutura foi definida por partes como: A extração de recurso, preparação e rotulagem do modelo candidato, treinamento *off-line* e a recomendação do modelo *on-line*. Com base nos testes o modelo foi capaz de selecionar em média três modelos eficazes para previsão de cargas.

Em 2020, *Andriopoulos et al.* (*ANDRIOPOULOS et al.*, 2020), propuseram uma previsão de cargas utilizando diferentes bancos de dados com demanda de baixo nível de escala e de intervalos de tempo, com dimensões distintas, na cidade de Trento - Itália. A metodologia desenvolvida utilizava um modelo de Rede Neural Artificial, com características estatísticas (Autocorrelação) para cada conjunto de dados de séries temporais realizando então

um pré-processamento de modo a utilizar as vantagens do algoritmo comparando-o a outro modelo de rede neural padrão aplicado a previsão de carga elétrica. No entanto, o modelo proposto foi capaz de fornecer soluções eficientes para o problema de previsão. Destaca-se que a previsão sempre foi uma tarefa desafiadora para os cientistas e para os setores elétricos.

No ano de 2020, Hafeez *et al.* (HAFEEZ *et al.*, 2020) desenvolveram um modelo híbrido para a previsão a curto prazo, utilizando os dados históricos de cargas elétricas disponíveis da Companhia Elétrica, de três redes dos Estados Unidos da América (FE, Dayton e EKPC). O modelo desenvolvido foi comparado com outros modelos de inteligência artificial. A estrutura do modelo híbrido foi apresentada em etapas. Inicialmente realizaram o processamento de dados, baseado em uma seleção de dados candidatos a entrada da rede, resolvendo o problema da dimensão das cargas voláteis da microgrid, e para o treinamento, foi utilizada a técnica de aprendizado profundo, desenvolvida por Taylor and Hinton (2011). Um módulo de otimização foi desenvolvido para ajustar os parâmetros e consequentemente minimizar o erro na previsão. O modelo híbrido mostrou-se eficiente ao comparar com outras técnicas de conhecimento da literatura.

Liu *et al.* (2019) desenvolveram três técnicas para prever cargas elétricas de curto prazo a nível de subestação e utilizaram dados históricos das cargas, o clima e os dados do mês, coletados a cada meia hora por medidores inteligentes. Eles relataram a dificuldade encontrada ao realizar a previsão a nível de subestação com transformadores devido às influências e condições da operação na subestação e, então propuseram: i) utilizar o efeito das condições de operação da subestação da carga dos transformadores em paralelo, ii) usar o Fator de Distribuição de Carga e iii) fazer a previsão da carga do transformador.

O trabalho proposto por Sun *et al.* (2016) foi de realizar previsões de cargas elétricas a curto prazo utilizando dois estudos de casos: i) uma subestação com seis alimentadores e, ii) uma subestação com quatro alimentadores com dados retirados de medidores inteligentes. Os resultados são comparados com dois modelos de regressão múltipla e uma rede neural artificial simples. Utilizaram o fator de distribuição de carga para regularizar as “anormalidades/desestabilidade” das cargas dos “nós” e incorporar em um modelo de rede neural com a Transformada Wavelet (GROSSMANN; MORLET, 1984; MEYER, 1985). Um modelo de controle estatístico de processo, usando regras, foi utilizado para monitorar a carga real e apontar anomalias de acordo com cargas anteriores, havendo falha, a operação de comutação é realizada fazendo com que mudanças significativas sejam capturadas por regras.

Como conclusão o modelo proposto detectou anormalidades e forneceu qualidade nas previsões a curto prazo e com baixos esforços computacionais.

Em 2020, Sideratos *et al.*, realizaram previsões em dois estudos diferentes de casos interconectados e isolados de um sistema de energia de Creta, o método faz primeiramente um agrupamento dos dados de entrada utilizando regras de *fuzzy* (ZADEH, 1965; ZADEH, 1988). Logo após, as entradas são distribuídas para treinamento com a rede neural de base radial usando uma técnica de validação cruzada tripla, os dados de entrada são transformados em espaço tridimensional, e as previsões realizadas por uma rede neural convolucional com treinamento empregando algoritmo de otimização de Adam. O treinamento é realizado em duas etapas, a primeira considerada autônoma e a segunda usando dados de entrada transformado em matrizes tridimensionais. Os resultados mostraram que o modelo proposto é superior aos modelos tradicionais, ressalta-se que a eficácia está no agrupamento *fuzzy*.

Um método de previsão de carga a curto prazo usando redes neurais artificiais integradas foi apresentada por Shafiu *et al.* (2021). Eles utilizaram duas arquiteturas para a previsão em dados de séries temporais com capacidade de lidar com longos dados de série temporal. Eles apresentaram um modelo híbrido capaz de extrair e facilitar recursos ocultos das sequências de carga para fornecer a previsão da carga, basicamente utilizou-se um módulo de rede neural de convolução, de memória longa de curto-prazo e um módulo de fusão de recursos. O conjunto de dados utilizados foram de diferentes semanas e os dados ausentes foram ajustados conforme a carga do registro anterior. Em comparação a outros modelos, o proposto superou outras redes no uso das métricas MAE, RMSE, MAPE e R^2 .

Em 2020, Santos e Chaucoski em seu trabalho de previsão do consumo de energia utilizaram dados dos anos de 2004 a 2020, sem *outliers* (dados com ruídos ou duvidosos) pela plataforma da Empresa de Pesquisa Energética (EPE - Empresa Pública) da região sudeste do Brasil. Eles avaliaram modelos utilizados com frequência na literatura a fim de verificar a eficiência dos métodos ARIMA (BOX; JENKINS, 1976; O'DONAVAN, 1983) e rede neural artificial (WIDROW; LEHR, 1990; KARTALOPOULOS, 1997; HAYKIN, 2001) para realização de previsão em séries temporais por meio de dados histórico da Empresa. Observou-se um aumento do consumo ao longo dos anos e a existência da sazonalidade, padrões que se repetem em período fixo de tempo. Neste trabalho concluiu-se que os métodos utilizados apresentaram resultados próximos dos fornecidos pela empresa EPE a qual desenvolve estudos relacionados ao setor energético do país.

Jarndal e Husain, em 2020, na pesquisa para previsão de cargas elétricas utilizaram um banco de dados com registro de temperatura (°C), umidade relativa (%) e a carga (kW) de três anos, sendo dois anos para treino e validação e um ano para testes. O uso da rede neural perceptron multicamadas (MLP) (WERBOS, 1974; SANTOS; CARVALHO, 1997) em cascata realiza a incorporação de mais pesos em suas conexões, neste sentido utilizou-se mais informações aos neurônios nesta arquitetura. Ao contrário da MLP em cascata, utilizou-se uma rede dinâmica recorrente, com conexões *feedback*. Um modelo não paramétrico baseado em probabilidade e que utiliza regra bayesiana para resolver problema de previsão. Em comparação entre as técnicas utilizadas, os pesquisadores concluíram que todos os modelos são eficientes, porém a arquitetura do modelo proposto é a mais adequada para a previsão demonstrando melhor desempenho em relação ao atraso embutido e *feedback* das conexões.

Takiyar *et al.* (2017) propuseram em sua pesquisa um modelo híbrido para resolver o problema de previsão de séries temporais de carga elétrica. O modelo apresenta o hibrismo com a rede ARTMap Fuzzy (CARPENTER; GROSSBERG, 1988; CARPENTER *et al.*, 1992; LOPES, MINUSSI, LOTUFO, 2005) e a Transformada de Wavelet (TW) para o tratamento (pré-processamento) dos dados não estacionários das demandas das cargas elétricas. Neste trabalho utilizaram os dados de carga de New South Wales. Os autores concluíram que o modelo híbrido é mais eficiente do que os métodos utilizados separadamente.

Lomas-Barrie *et al.* (2021) utilizou o modelo de rede neural artificial, ArtMap Fuzzy para fazer reconhecimento de visão com um vetor específico nomeado *Boundary Object Function* (BOF), usado para escala, rotação, translação com capacidade de descrever peças com a mesma quantidade de dados, sendo ferramentas para detecção/extração de recursos de pontos (*pixels*) dos objetos. A rede neural artificial ARTMAP-Fuzzy classificou os vetores BOF em um rápido reconhecimento de objetos com o treinamento e a representação do objeto é implementada no Módulo Zybo Z7-20. Os autores concluíram que em comparação ao desempenho da detecção dos objetos, o processamento foi mais rápido com o uso da metodologia e os resultados apresentados foram focados na extração rápida do reconhecimento de objetos com uso do BOF.

Matias *et al.* (2021) investigaram o modelo de rede neural artificial ARTMAP-Fuzzy para melhorar a questão de proliferação das categorias. Este é um problema que a rede neural ARTMAP Fuzzy pode sofrer quando há utilização de dados com ruídos. Os autores descreveram que alguns trabalhos têm realizado métodos de pré-processamento na categorias, ou até mesmo substituindo os hiper-retângulos por hiperesferas, gaussianas e politopos. Propuseram uma nova formulação para o teste de vigilância e atualização de pesos, o modelo

intitulado de ARTMAP-Fuzzy com Área de Influência (FAM-AI) foi em geral capaz de melhorar a generalização, porém segue o problema na sensibilidade de apresentaçãodos dados para a rede.

Smyl S. (2020) apresentaram um novo método híbrido, com pré-processamento no vetor de entrada em tempo real utilizando o método de suavização exponencial combinando com redes neurais avançadas de memória de curto prazo (LSTM) (HOCHREITER, SCHMIDHUBER, 1997).O método garante uma previsão de séries temporais de forma mais precisa do que as de modelos estatísticos clássicos ou de outros algoritmos de máquina de aprendizado.

Em 2021, Yongjian *et al.*, expõe que o diagnóstico na falha do rolamento de um equipamento mecânico é importante para uma operação e a segurança se torna indispensável para o equipamento. Propuseram um método de extração de características de falhas com base na distância de Manhattan por image.O método realiza cálculos entre a matriz local e matrizmédia, a característica de falha do rolamento podendo efetivamente distinguir os sinais de rolamento normal, falha do anel interno e externo e falha da esfera. Os autores verificaram a eficácia da metodologia aplicada com o uso de experimentos de simulação e alcançaram resultados satisfatórios.

Zhang *et al.*(2020) relataram que os sistemas de aquecimento, ventilação, ar-condicionado e sistema de iluminação são os principais consumidores de energia em edifícios, e falhas nos dispositivos de controle e manutenção leva a sérios desperdícios de energia. Em geral, o desempenho operacional de energia do edifício não é constante por causa das degradações, mudanças de inquilinos e variações em ambientes externos dificultando a eficácia dos métodosde previsão. A metodologia proposta utiliza a distância de Manhattan entre a diferença de uma situação prevista e uma situação conhecida (real).Os resultados mostraram que a distância de Manhattan ponderada são eficazes e úteis para modelos de previsão de cargas de energia de edifícios.

Em 2021, Zhang *et al.*,expõe que a tecnologia de comunicação e indústria automotiva desenvolveramo sistema VANET (Rede Ad-Hoc Veicular), aumentando a segurança na direção e no tráfego. Em VANET aplica-se cenários de segurança e sem segurança, embasado na troca de mensagens entre veículos, então torna-se importante oenvio dessas mensagens, não sendo adulteradas. Por exemplo, um veículo malicioso pode transmitir informações que a estrada não está congestionada, mas realmente ocorreu um incidente e congestionou. A metodologia proposta é um modelo de mobilidade de Manhattan que simula o movimento de

veículos nas estradas da cidade. Os resultados experimentais apresentaram melhores desempenhos em termos de probabilidade na decisão certa em relação a métodos similares.


Gao e Li (2020) propuseram um modelo de aprendizado de máquina (AHA; KIBLER; ALBERT, 1991) baseado no algoritmo KNN(k-Nearest Neighbor) para identificar com precisão proteínas SNARE (proteína de fusão de membrana). A perda desta proteína pode causar doenças neurodegenerativas, doenças mentais, câncer etc. Foram usados quatro tipos de medidas de distância, Chebyshev, Euclidiana, Manhattan e Minkowski. Neste trabalho houve diferentes combinações de medidas de distância com algoritmo KNN destacando-se o modelo construído sem amostragem e a distância de Manhattan.

3 PREVISÃO DE CARGA ELÉTRICA

É de interesse e competência de cada país a formulação e a implementação de políticas no setor energético, conforme normas e leis do órgão responsável pelo planejamento, monitoramento e segurança do setor elétrico para o suprimento de energia elétrica aos consumidores. Este órgão trará desenvolvimento eficaz para os setores de energia com resultados de pesquisas e de estudos a fim de garantir a sustentabilidade, o bem-estar social e, de modo geral, o coletivo. Para todo atendimento de projetos e de metas de geração, transmissão e distribuição de energia elétrica é necessário um sistema composto de planejamento prevendo as necessidades das regiões por cerca de horizonte de períodos.

A eletricidade produzida nas usinas geradoras percorre um caminho até chegar nas unidades consumidoras e passam por diversas subestações. Elas dependem dos níveis de tensão, das entradas e saídas, tipo de construção (interno ou externo), pequenas ou grandes instalações, equipamentos dos transformadores, disjuntores, para-raios, resistores, podendo operar com uma equipe treinada, semiautomatizada ou automatizada (MCDONALD, 2012). A Figura 1 apresenta, de forma simples, a diversidade das etapas do Setor Elétrico, que compreende a interligação da geração até as unidades consumidoras, contudo o cenário desta pesquisa são subestações.

Figura 1–Diversidade do Setor Elétrico.




Fonte: Própria Autora.

3.1 FATORES QUE INFLUENCIAM A PREVISÃO

De forma geral, os Setores de Energia são impactados por diversos fatores (GROSS, GALIANA, 1987) que influenciam a previsão das cargas elétricas, podendo ser afetados pela condição socioeconômica do país. Em destaque, a Pandemia causada pela COVID-19, tem, de fato, impactado a economia mundial e regional atingindo o consumo de energia por meio das devidas restrições oriundas das decisões dos setores públicos, como por exemplo os *Lockdowns*. Este é um fator que deixa a economia com incertezas nos planejamentos públicos e privados. Na Figura 2 é ilustrado o impacto gerado pelo PIB do Brasil.

Figura 2 – PIB Trimestral Realizado (T/t-4) x Incerteza (FGV).



Fonte: Elaborado por EPE a partir de dados do IBGE(2020a) e FGV (2020).

Outro fator, que pode influenciar na previsão das cargas elétricas, são os índices de densidade demográfica (hab/km^2). A mudança demográfica pode atingir o crescimento econômico e ameaçar os recursos limitados (CARVALHO *et al.*, 2010, EHRLICH, 1968).

Fatores do tempo, como o horário, dia do ano, dia do mês, dias úteis da semana, finais de semana, feriados, todos esses elementos influenciam no comportamento das cargas elétricas.

Mudanças climáticas são outro fator que exerce uma grande influência na previsão regional ou global. Elas são classificadas em chuvas intensas, ondas de frio ou calor, estiagem, velocidade do vento e umidade e, podem impactar os índices de base dos dados em instituições públicas ou privadas (LIN *et al.*, 2006).

Os fatores aleatórios são eventos esporádicos que ocorrem em algumas circunstâncias atingindo o comportamento do perfil das cargas elétricas, podendo ser uma programação não planejada na manutenção de equipamentos, greves ou paralizações nas indústrias, manifestações populares e eventos esportivos, como Copa ou Olimpíadas (MURTO, 1998).


3.2 HORIZONTE DE PREVISÃO

O horizonte é um tempo de períodos no qual a estrutura do Sistema Elétrico determina os planejamentos e as estratégias para os projetos a fim de implementar fontes de energia e as manutenções no sistema para o funcionamento ou operação. Esses períodos, na forma de intervalos de tempo, assessoram as previsões das cargas elétricas e são classificados em (MURTO, 1998; BAO, 2002):

- a) Longo Prazo: período entre 10 e 20 anos. Prazo utilizado para o planejamento e a expansão no Sistema Elétrico, com foco nas fontes de geração de energia se estendendo até a manutenção ou troca de equipamentos;
- b) Médio Prazo: período favorável ao planejamento de produção, intercâmbio e programas de reparos, ocorre em poucas semanas podendo se estender por anos;
- c) Curto Prazo: essencial para análise de maior qualidade e segurança diária do sistema elétrico de potência, intervalos de meia hora, poucas horas, poucos dias até uma semana;
- d) Curtíssimo Prazo: período para tomadas de decisão de segundos a minutos aplicado no planejamento, produção on-line e no controle.

A Figura 3 contempla a diversidade dos períodos das classificações nos horizontes de tempos em relação à previsão de cargas elétricas.

Figura 3 – Classificação dos Períodos das Previsões.



Fonte: Própria Autora.

É de grande relevância e fundamental a realização de previsões de cargas elétricas para o gerenciamento e o monitoramento do sistema elétrico de potência favorecendo a economia, segurança e a confiabilidade nas demandas de consumo de energia. Optou-se, nesta pesquisa, trabalhar com previsão de cargas elétricas a curto prazo com horizonte de 24 horas à frente.

3.3 TÉCNICAS PARA PREVISÃO

Ao longo das últimas décadas, o surgimento de métodos de cálculo para realização de previsões de cargas elétricas tem sido observado em um número considerável na literatura especializada. As técnicas utilizadas, com relevância, são de métodos estatísticos e os sistemas especialistas (O'DONOVAN, 1983, MURTO, 1998, MOGHRAH & RAHMAN, 1989, NASSAR, 1998, ABREU, 2012):

- a) Métodos Estatísticos: precisam de uma modelagem prévia da carga elétrica. Para usar um dos algoritmos é primordial que se conheça as características do ambiente que advém a carga. Esse comportamento pode ser acompanhado de efeitos atmosféricos (temperatura do clima, velocidade do vento, umidade do ar etc.) e efeitos de dias não convencionais (feriados, greves etc.). São exemplos de técnicas, a Regressão Linear Simples ou Múltipla, Alisamento Exponencial, Espaço de Estado e Filtro de *Kalman*, ARIMA de Box & Jenkins (conhecida comumente como previsão dinâmica);
- b) Sistemas Especialistas: são programas computacionais baseados na Inteligência Artificial (IA) capazes de imitar o raciocínio humano. Estes programas estão aptos a interagirem com os usuários na resolução de problemas, bem como devem oferecer explicações satisfatórias de seu raciocínio e, ainda, devem ser capazes de continuar aprendendo ao longo do tempo. Há dois paradigmas para o desenvolvimento de sistemas especialistas, em IA, que são: o paradigma simbólico em que o conhecimento do especialista é disposto numa base de conhecimentos, no qual as inferências são representadas por meio de regras do tipo SE-ENTÃO e o paradigma subsimbólico (conexionista) empregando as redes neurais artificiais para representar e solucionar problemas num domínio específico.


As técnicas de métodos estatísticos e de sistemas especialistas desenvolveram um crescimento exponencial para pesquisas em relação a previsão de cargas elétricas.

Atualmente, o surgimento de modelos híbridos tem sido destaque na literatura. No entanto, esta pesquisa tem o uso de um sistema especialista constituído por uma rede neural artificial intitulada ARTMAP Euclidiana que será descrita no Anexo A e, ARTMAP Manhattan.

3.4 SISTEMA PREVISOR MULTINODAL

Altran (2009) formula um novo modelo de sistema predictor de cargas elétricas, “um sistema inteligente em que a previsão é realizada considerando-se vários pontos (nós) da rede elétrica...”, realizando a previsão aplicada em ambiente de distribuição de energia elétrica na demanda da diversidade comportamental de tipos de barramentos do sistema elétrico e de diferentes consumidores. Na referida publicação é considerada como Carga Global a soma do conjunto dos valores das cargas de todas as subestações. A Figura 4 ilustra, de maneira pictórica, o conjunto de n subestações considerando como nó cada subestação.

Figura 4 – Ilustração Carga Elétrica Global.



Fonte: Própria autora.

Os nós podem expressar pontos de interesse para a previsão, tais como subestações, transformadores, barramentos etc.

A formulação matemática é extraída da referência (ALTRAN, 2009). A carga global (CG) é assim definida:

$$CG = \sum_{i=1}^n CL_i \quad (1)$$

sendo:

CG : carga global do sistema elétrico;

CL_i : i -ésima carga local;

n : número de nós.

As previsões de cargas elétricas realizada neste trabalho utiliza a Carga Global e Carga Nodal. A Figura 5 simbolicamente representa a subestação de um determinado local.

Figura 5 – Representação Simbólica da Carga Elétrica Nodal (Local).



Fonte: Própria autora.

O sistema predictor inteligente a ser desenvolvido, nesta pesquisa, é constituído por um módulo predictor da carga global (total), bem como é realizada a previsão das cargas locais (previsão multinodal). Será formulada a previsão de carga multinodal baseada na rede neural ARTMAP Euclidiana com implementação do conceito de treinamentos direto e reverso apresentados (sugeridos) nas referências Abreu *et al* (2018), Amorim (2019) e Amorim *et al*. (2020) (uso da rede neural ARTMAP-Fuzzy).

A rede neural ARTMAP Euclidiana foi escolhida por tratar-se de uma formulação que não necessita realizar as operações de normalização e de complemento como empregado na rede neural ARTMAP-Fuzzy. Desta forma, os vetores de entrada e de saída possuem uma dimensão correspondente a 50% em comparação à arquitetura ARTMAP-Fuzzy. Como consequência, há a expectativa de redução do tempo de execução do treinamento da rede neural. Também, há a expectativa que a qualidade das soluções seja equivalente ou superior.

Com essa proposta, para cada nó da rede neural, o treinamento é realizado somente levando-se em conta o módulo **ART_b** de cada nó, aproveitando-se do treinamento na rede

neural **ART_a** já realizado na previsão global. Com isto, o tempo de processamento é imensamente inferior em comparação ao tempo de processamento necessário para realizar a previsão multinodal ao modo proposto em Altran(2008). De acordo com os experimentos relatados em Amorimet *al.* (2020), a precisão dos resultados tem sido preservada, ou seja, os resultados tem sido satisfatórios (MAPE inferior a 5% atendendo a recomendação do setor elétrico). Ressalta-se que a formulação original de Altran (2008) tem proporcionado a previsão multinodal com tempo de processamento final bastante inferior, se comparado ao tempo de processamento na previsão multinodal observado na literatura especializada. Deduz, portanto, que há uma considerável redução do tempo de processamento, por hipótese, sem comprometer a qualidade da previsão.

Inicialmente, recorre-se ao conceito de Fator de Participação da Carga Global (*FPCG*) (ALTRAN, 2008):

$$FPCG_p(h) = \frac{CL_p(h)}{CG(h)} \quad (2)$$


sendo:

$FPCG_p(h)$: fator de participação da carga global referente à barra p e horário h ;

$CL_p(h)$: carga elétrica da subestação p em relação a hora h ;

$CG(h)$: carga elétrica global em relação a hora h .

A Figura 6 apresenta o modelo Previsional Multinodal.



Fonte: Própria autora.

Observa-se que a variação dos parâmetros $FPCG_p$ (para $p = 1, 2, \dots, n$) fica compreendida entre 0 e 1 e possui um comportamento que flutua sutilmente em torno de um valor médio. Com isso, é bem provável que se consiga um resultado mais favorável, se comparado com o resultado setado em cima da carga real, podendo gerar alguns ajustes convenientes para melhorar a previsão, por exemplo, o uso do conceito de “corretor pro rata” (AMORIM *et al.*, 2020) que tem contribuído para a melhoria dos resultados finais.


As nove subestações estudadas nesta pesquisa pertencem a um sistema de potência contendo particularidades distintas nos transformadores, com variações nas tensões e potências. O quadro 1 especifica os transformadores das subestações e particularidades das regiões.

Quadro 1 – Característica das Subestações.

Subestações	Tensão(kV)	Potência (MVA)	Particularidades da Região
Kopu	2x110/66	2x45	Assentamento - 900 habitantes
Cambridge	2x110/11	2x38	Cidade pequena - 19.150 habitantes
Hamilton 11kV	2x110/11	2x40	Cidade Mediana – 176.500 habitantes
Hamilton 33kV	2x220/33	2x100	
Hinuera	2x110/33	1x30+1x20	Assentamento – 1.152 habitantes
Waihou	3x110/33	3x20	Vilarejo – xx habitantes
Waikino	2x11/33	2x30	Vilarejo – 213 habitantes
Te Awamutu	2x110/11	2x40	Cidade pequena - 13.100 habitantes
Kinleith	2x110/33	1x30	Assentamento – 2.440 habitantes

Fonte: Kenji (2011) Adaptado.

Figura 8 – Perfil das Cargas Elétricas das Subestações.



Fonte : Própria Autora.

A Figura 8 mostra o comportamento real da carga elétrica da data a realizar a previsão. Nota-se que as linhas mantêm uma característica própria para cada subestação, os valores das amostras (de meia em meia hora) no eixo da abcissa (horizontal) e no eixo da ordenada (vertical) os valores das cargas em [MW].

5 DESCRIÇÃO DOS DADOS

Uma pesquisa a ser realizada necessita de um banco de dados com máximo de informações necessárias para o procedimento e desenvolvimento da investigação relacionada ao tema abordado e selecionado pelos operadores. Os dados explorados nesta pesquisa foram concedidos pela Empresa de Energia Nova Zelândia. As informações contidas em tabelas engloba dia da semana, dia do mês, ano, horário (de meia em meia hora), temperatura e as cargas elétricas de acordo com o período registrado. Os dados utilizados foram: os dias da semana, o horário e a carga elétrica correspondente a cada subestação. Os dias da semana e o horário estão representados de forma binária. A semana possui sete dias e, então na representação tem-se um total de 3 bits. Já o horário é representado com 6 bits devido o período de 24 horas ser medido de meia hora. Esses dados são intitulados dados exógenos e suas representações encontram-se no Quadro 2.

Quadro 2 – Representação dos Dados Exógenos.

DADOS EXÓGENOS			
Dias da Semana	Binarização	Horário	Binarização
Segunda-feira	001	1ª Amostra	000001
Terça-feira	010	2ª Amostra	000010
Quarta-feira	011	3ª Amostra	000011
Quinta-feira	100	4ª Amostra	000100
Sexta-feira	101	5ª Amostra	000101
Sábado	110	⋮	⋮
Domingo	111	48ª Amostra	110000

Fonte: Própria Autora.

Nesta pesquisa utilizou-se dados históricos das cargas elétricas, incluindo a carga elétrica máxima e a carga elétrica mínima e para completar o banco de dados, também, utilizou-se a média das cargas elétricas. Este mecanismo é efetivado para o período de meia em meia hora (48 amostras diárias). No Quadro 3, mostra-se a composição dos dados exógenos de cargas elétricas. Ressalta-se que a simulação realizada considerando-se somente os dados exógenos não forneceram resultados tão eficientes. Neste caso, optou-se pelos dados exógenos incorporando o método do janelamento.

Quadro 3 – Dados Exógenos das Cargas Elétricas.

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

Fonte: Brasil(2020) Adaptado.

Os dados históricos das cargas foram elaborados por um procedimento conhecido na literatura como deslocamento de janela ou movimento da janela (PARK, SHARKAWI, MARK II, 1991). O tempo discreto h adotado é de meia em meia hora. Esse tempo discreto pode ser tomado usando-se outros modos de discretização, por exemplo, 5 em 5 minutos, dependendo da base de dados disponível.

Cada janela é formada pelos dados de entrada e de saída da rede neural. A entrada corresponde a 4 valores da carga: $C(h-3)$, $C(h-2)$, $C(h-1)$ e $C(h)$, enquanto a saída corresponde ao valor da carga $C(h+1)$. Deste modo, deslocando-se essa janela pode-se percorrer todo o período de interesse, tanto para o treinamento como para a previsão. No Quadro 4, é mostrada, de forma genérica, a posição das cargas em seus instantes na estrutura de janela temporal.


Quadro 4 – Cargas Elétricas em Janelamento.

Amostras	Posição do Janelamento das Cargas Elétricas				
1	$C(h-3)$	$C(h-2)$	$C(h-1)$	$C(h)$	$C(h+1)$
2	$C(h-2)$	$C(h-1)$	$C(h)$	-	-
3	$C(h-1)$	$C(h)$	-	-	-
⋮	$C(h)$	⋮	⋮	⋮	⋮
48	-	-	-	-	-

Fonte: Própria Autora.

A carga no instante h (hora atual) refere-se a carga real e a carga no instante $(h + 1)$ (hora desejada) a carga prevista. A Figura 9 apresenta sistematicamente a representação de uma série temporal utilizada nesta pesquisa.

Figura 9–Representação Distinta das Janelas.



Fonte: Altran (2010) Adaptado.

O agrupamento de dados da entrada e saída (vetor entrada e saída) para o intervalo da série temporal, obtidos de meia em meia hora está definido da seguinte forma (LOPES, MINUSSI, LOTUFO, 2005):

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


$$B(h) = [C(h+1)], \quad Y \in \mathbb{R}^1 \quad (4)$$

Em que:

- t : vetor de tempo respectivo aos dados históricos (dados exógenos);
- $C(h-q)$: valor da carga q instantes, antecedente a carga elétrica no instante h ;
- $C(h+1)$: valor da carga referente ao instante subsequente à carga no instante h ;
- h : instante retratado a meia hora.

Na Figura 10 apresenta-se o esquema utilizado a fins de simulação com o uso da Rede Neural ARTMAP Euclidiana com Treinamentos Direto e Reverso.

Figura 10 - Estrutura dos Dados para Simulação.



Fonte: Própria Autora.

6 REDE NEURAL ARTMAP EUCLIDIANA

A Rede Neural ARTMAP Euclidiana é uma arquitetura neural descendente das redes neurais ARTMAP Gaussiana, elaborada por Williamson em 1996, (WILLIAMSON, 1996), que utilizou a distância de Mahalanobis, sendo a primeira investigação em relação a geometria elíptica e não a de hiperretângulos utilizadas na rede neural ARTMAP-Fuzzy para seleção de função categorias visando o agrupamento dos dados de entrada. Contudo, ressalta-se que a “mãe” de todas essas linhagens de redes neurais é a rede neural ART (Adaptive Resonance Theory) desenvolvida por Grossberg (GROSSBERG, 1987). Em 2002, Vuskovic e Du utilizaram as equações da distância de Mahalanobis (VUSKOVIC, DU, 2002 a) e a distância Euclidiana (VUSKOVIC, DU, 2002 b) sem a normalização e a complementação dos vetores padrão de entrada.

Logo, a dimensão dos vetores é reduzida pela metade, implicando em uma significativa diminuição de custo computacional. Ainda assim a entrada de dados é composta por vetores binários, muito importante para atribuição nos resultados (dados exógenos) e vetores analógicos (carga elétrica) podendo realizar as simulações simultaneamente sem a preocupação de cálculos quando há uso de filtros ou normalização (norma-1, hiperretângulos) como de prática utilizado em pesquisas no pré-processamento de dados, sendo assim inalterados, ou seja o conjunto de dados de entrada da rede permanece originais. Portanto, a vantagem se faz notória sem grandes desafios para o treinamento e previsão.


Este modelo de rede tem uma arquitetura vantajosa com a utilização da distância euclidiana, a redução dos vetores de entrada e na capacidade de aprender e preservar suas informações já armazenadas nas matrizes sinápticas, ou seja, permite a inserção de novas informações sem a necessidade de reiniciar a fase de treinamento, como ocorre nas redes neurais artificiais (por camadas) em pesquisas atuais.

O ANEXO B aborda o surgimento da família da Teoria da Ressonância Adaptativa e suas características (GOMES, 2017).

O treinamento da Rede Neural Euclidiana é supervisionado contendo em sua estrutura dois módulos, ART_a e ART_b interconectados com um único módulo $Inter - ART$. De modo geral, os módulos ART_a e ART_b iniciam com os devidos vetores de entrada (I^a) e de saída (I^b), distinguindo o neurônio vencedor por meio de uma “oscilação” entre as camadas com aprovação dos respectivos testes de vigilância. Enfim, a aprendizagem ocorre quando há “o casamento” entre as entradas e as saídas realizada pelo módulo $Inter - ART$. Na Figura 11

ilustra-se a estrutura da Rede Neural ARTMAP Euclidiana em trato de mapeamento funcional de vetores de entrada, módulo ART_a a esquerda e saída desejada, módulo ART_b a direita.

Figura 11 – Estrutura ARTMAP Euclidiana.




Fonte: Própria Autora.

A rede ARTMAP Euclidiana possui funções específicas para realizar o processo de classificação de padrões, os processos são intercalados em camadas (etapas), estruturalmente como da família da Teoria da Ressonância Adaptativa (CARPENTER *et al.*, 1992).

A estrutura e o algoritmo da Rede Neural ARTMAP Euclidiana estão detalhados no ANEXO A.


Nesta pesquisa, utilizam-se dois tipos de Treinamento: Direto (clássico) e o Reverso. A apresentação dos vetores de entrada, os dados exógenos, cargas passadas (janelamento) e carga corrente e saída inseridos na rede para os treinamentos são mostrados na Figura 12 e na Figura 13. Esta estratégia tem sido usado, com sucesso, em várias publicações (ALTRAN, *et al.*, 2009; AMORIM *et al.*, 2020; LOPESet *al.*, 2005, entre outras publicações). Contudo, para a composição do vetor de entrada, relativa aos valores da carga, podem ser usadas estratégias diferenciadas, evidentemente, com vistas para melhorar a qualidade das previsões.

Figura 12 – Vetores Entrada, Módulo ART_a .



Fonte: Própria Autora.


Figura 13 – Vetores Saída, Módulo ART_b .



Fonte: Própria Autora.


No entanto, para o Treinamento Reverso (usado na realização da previsão multinodal) com o uso da Rede Neural ARTMAP Euclidiana, utiliza-se o fator de participação no vetor saída da rede. As Figuras 14 e 15, apresentam os vetores utilizados para este treinamento.

Figura 14 – Vetores Entrada, Módulo ART_a , para Treinamento Reverso.



Fonte: Própria Autora.

Figura 15 – Vetores Saída, Módulo ART_b , para Treinamento Reverso.



Fonte: Própria Autora.

Em relação aos vetores de entrada a serem utilizados para simulação, tanto para treinamento direto, assim como para o treinamento reverso, as características permanecem as mesmas, ou seja a dimensão dos vetores contendo dados exógenos e os dados das respectivas cargas elétricas. Observa-se a modelagem com o Fator de Participação na saída do vetor para Treinamento Reverso.

7 REDES NEURAI APLICADAS NA PREVISÃO DE CARGA ELÉTRICA

Neste capítulo serão abordadas as propostas desta pesquisa, sendo todas para a idealização de Previsão de Cargas Elétricas, com o uso do Sistema Previsor Global e Sistema de Previsor Local. Os testes foram realizados com a rede neural artificial ARTMAP Euclidiana empregando o Treinamento Clássico para previsão global e o Reverso para previsões multinodais. A segunda arquitetura baseia-se em um tipo de geometria não euclidiana com uso da equação da distância de Manhattan (KRAUSE,1975). Com o uso da distância de Manhattan surge a rede neural ARTMAP Manhattan com treinamento direto utilizada no problema de previsão local.

7.1 ARTMAP EUCLIDIANA COM TREINAMENTO REVERSO

O uso desta arquitetura, Rede Neural ARTMAP Euclidiana, está relacionado ao ganho de tempo que pode ser proporcionado devido ao fato da não necessidade de realização das operações de normalização e da complementação dos vetores de entrada e de saída, ou de algum outro tipo ou modelo de filtragem de dados, reduzindo a dimensão dos vetores de entrada e saída pela metade. Isso representa um processamento mais rápido, ou seja, um baixo custo computacional (VUSKOVIC & DU, 2002). Outra motivação do uso desta rede, está na caracterização advinda da família da Teoria da Ressonância Adaptativa, com capacidade de aprender novos padrões, sem perder o conhecimento adquirido anteriormente, o que confere a este tipo de rede as características de plasticidade e da estabilidade, conhecido como dilema da estabilidade-plasticidade.

O objetivo principal desta pesquisa é realizar a análise do recente modelo de treinamento de dados intitulado treinamento reverso (AMORIM, *et al.*, 2020). Nesta pesquisa, o conceito do treinamento reverso será implementado na rede neural ARTMAP Euclidiana como uma contribuição diferencial.

Neste fase de exposição teórica, as conceituações usadas referem-se à fase de treinamento, a qual é a parte mais sensível e de maior custo computacional para a sua execução. A fase da previsão, a ser abordada em capítulo adiante, é executada em tempo ínfimo. É importante ressaltar que na fase de treinamento, há dois módulos neurais importantes (ART_a e ART_b), os quais recebem como dados de entrada o vetor $\mathbf{a}$ e o vetor $\mathbf{b}$ nos

módulos ART_a e ART_b , respectivamente. Na fase da previsão, o vetor $\mathbf{b}$ converte-se como sendo a saída da rede neural, ou seja, o diagnóstico final, sendo que no caso desta pesquisa é a previsão da carga. Para melhor entendimento, para a previsão da carga global tem-se uma rede neural treinada com memórias sinápticas ($\mathbf{W}_a^G, \mathbf{W}_b^G$ e $\mathbf{W}_{ab}^G$). Por sua vez, na previsão de carga multinodal, as bases sinápticas são: ($\mathbf{W}_a^G, \mathbf{W}_b^i$ e $\mathbf{W}_{ab}^i$, para $i = 1, 2, \dots, n$), sendo n : o número de nós de interesse da rede elétrica.

A pesquisa foi idealizada, portanto, em duas etapas principais. Primeiramente, visando-se a previsão global. Nesta etapa, realiza-se o treinamento global (Treinamento Clássico) considerando a carga total do sistema. Posteriormente, procede-se o treinamento levando-se em conta todos os nós de interesse da rede elétrica. Esta fase, constitui-se como sendo o treinamento multinodal. Nesta fase (treinamento multinodal) o tempo gasto para o processamento é relativamente pequeno, em razão de que em cada nó, a entrada possui uma dimensão unitária ($FPCG(h + 1)$). Contribui imensamente para a redução do tempo de processamento, o fato de que o módulo neural referente aos dados de entrada encontrar-seja concluído pela realização do treinamento referente à previsão da carga global. Esta é a grande vantagem oferecida quando se emprega o conceito de treinamento reverso (AMORIM *et al.*, 2020).

Ressalta-se que, na fase da previsão, $FPCG(h + 1)$ deve ser convertido em valor da previsão da carga no instante $(h + 1)$, multiplicando por $CG(h + 1)$.

Outra característica é o procedimento da troca de posição dos módulos ART_a e ART_b quando realizado no mecanismo de aprendizagem. Então o módulo, ART_a é inicializado com todas suas características e expressões, em seguida o módulo ART_b , neste processo não haverá decremento ou incremento em nenhum dos parâmetros como ocorre no módulo ART_a no treinamento clássico realizado pela rede neural ARTMAP-Fuzzy. Para melhor compreensão é apresentado o algoritmo passo a passo em ordem de programação para o treino dos dados das cargas elétricas multinodais.

1º Passo : Deve-se carregar a matriz $\mathbf{W}^a$ do treinamento anterior (Treinamento da Carga Global, que vem da 1ª Etapa, somente utilizando os neurônios ativos);

2º Passo : Leitura dos dados de entrada dos vetores padrão (I^a) da local;

3º Passo : Entrada dos vetores padrão de saída (I^b) da local;

4º Passo : Cálculo dos vetores de saída local (I^b) com uso do fator de participação da carga global da saída global (I^b);

5º Passo : Construção da matriz W^b , todos com valores iguais a zero;

6º Passo : Construção da matriz W^{ba} , todos com valores iguais a um;

7º Passo : Leitura do Parâmetros ($\rho_a, \rho_b, \rho_{ba}, \beta$ e ε);

8º Passo : Inicia-se o processo de treinamento. Cálculo da escolha da categoria de T_a e T_b ,

$$T_j^a = (I_j^a - W_j^a)(I_j^a - W_j^a)^T \quad (5)$$

$$T_k^b = (I_k^b - W_k^b)(I_k^b - W_k^b)^T \quad (6)$$

9º Passo : Módulo ART_a , escolha da categoria:

$$T_j^a = \min\{T_j: j = 1, \dots N\} \quad (7)$$

10º Passo : Cálculo do teste de vigilância usando aequação (8):

$$x_a = \frac{T_j^a}{\max(I_j^a I_j^{aT}, W_j^a W_j^{aT})} \geq \rho_a \quad (8)$$

12º Passo : Composição do vetor atividade $\mathbf{y}_j^a = [y_1^a y_2^a \dots y_N^a]$, com $y_j^a = 1$, se $j = J$ e $y_j^a = 0$, se $j \neq J$;

13º Passo : Caso ρ_a não seja satisfeito, então $T_j^a = \max(T_j^a) + 1$, ocorrendo o *reset* para evitar que uma seleção persista na mesma categoria durante o processo de busca e retome para o 9º Passo;

14º Passo : Módulo ART_b , escolha da categoria:

$$T_K^b = \min\{T_k: k = 1, \dots, N\} \quad (9)$$

15º Passo : Cálculo para teste de vigilância, com a função:

$$x_b = \frac{T_K^b}{\max(\mathbf{I}_K^b \mathbf{I}_K^{bT}, \mathbf{w}_K^b \mathbf{w}_K^{bT})} \geq \rho_b \quad (10)$$

16º Passo : Se ρ_b for satisfeito, faça o cálculo do módulo *Inter-ART*, com a função

$$x_{ba} = |\mathbf{y}^a \wedge \mathbf{W}_K^{ba}| > \rho_{ba} \quad (11)$$

17º Passo : Caso critério de ρ_{ba} seja satisfeito, então atualize a matriz $\mathbf{W}_b$

$$\mathbf{W}_K^b = \beta(\mathbf{I}_K^b) + (1 - \beta)\mathbf{W}_K^b \quad (12)$$

18º Passo : Atualizar a matriz $\mathbf{W}^{ba}$, com $\mathbf{w}_K^{ba} = 0$ e $\mathbf{w}_J^{ba} = 1$;

19º Passo : Se x_{ba} não for satisfeito, *reset*, $T_K^b = \max(T_K^a) + 1$, e retorne ao 9º Passo, para uma nova escolha de categoria.

A finalização da Previsão de Carga Multinodalestá na utilização da Rede Neural ART Euclidiana em um único módulo, sem decremento no parâmetro de vigilância. A matriz $\mathbf{W}^a$ carrega as informações da matriz utilizada na previsão global anterior e servirá para

oscálculos da escolha da categoria e do teste de vigilância. A saída real é a entrada das cargas locais e a saída prevista advém do processo entre as matrizes $\mathbf{W}^{ba}$ e $\mathbf{W}^b$. O algoritmo da fase de previsão é descrito da seguinte forma:

1º Passo : Leitura dos dados de entrada;

2º Passo : Leitura do parâmetro de vigilância (ρ_a);

3º Passo : Matriz peso $\mathbf{W}^a$;

4º Passo : Cálculo da escolha da categoria de T_a ,

$$T_j^a = (\mathbf{I}_j^a - \mathbf{W}_j^a)(\mathbf{I}_j^a - \mathbf{W}_j^a)^T \quad (13)$$

5º Passo : A escolha da categoria, com

$$T_j^a = \min\{T_j: j = 1, \dots, N\} \quad (14)$$

6º Passo : Cálculo do teste de vigilância:

$$x_a = \frac{T_j^a}{\max(\mathbf{I}_j^a \mathbf{I}_j^{aT}, \mathbf{W}_j^a \mathbf{W}_j^{aT})} \geq \rho_a \quad (15)$$


7º Passo : Teste de Vigilância, se $x_a \geq \rho_a$, for satisfeito, então calcula-se a saída prevista. Senão, ocorre *reset*, $T_j^a = \max(T_j^a) + 1$, retorne para o 5º Passo.

8º Passo : Cálculo do MAPE e a elaboração do gráfico;

9º Passo : Fim do Algoritmo.


O procedimento, passo a passo, do Treinamento Reverso está apresentado no Fluxograma ilustrado na Figura 16:

Figura 16–Fluxograma da Rede Neural ARTMAP Euclidiana com Treinamento Reverso.



Na Figura 17 ilustra-se a estrutura da previsão da carga multinodal com o modelo do Treinamento Reverso. A estrutura composta por duas etapas, do Sistema Previsor Global e Sistema Previsor Local, consiste em realizar a previsão global, conjunto de todas as cargas elétricas das subestações e a previsão local, que se refere a carga elétrica da subestação no local.

Figura 17 – Estrutura da Previsão Local com Treinamento Reverso.



Fonte: Própria Autora.


Em cada módulo referente à previsão local, o valor da carga p é ultimada mediante a multiplicação do parâmetro $FPCG_p$ pelo valor da carga total.

7.2 ARTMAPMANHATTAN

A segunda metodologia apresentada neste trabalho se refere a Geometria nãoEuclidiana, intitulada ARTMAP Manhattan, por utilizar a métrica da distância de Manhattan (referente as ruas quadriculadas da ilha de Manhattan) também conhecida como distância dotaxista ou distância L_1 , em que a distância entre dois pontos é a soma das

diferenças absolutas de suas coordenadas. Na Figura 18 mostra-se uma foto, via satélite, do centro e as ruas quadriculadas da ilha de Manhattan da cidade de New York.

Figura 18—Mapa das Ruas Quadriculadas da Ilha de Manhattan.



Fonte: <https://thumbs.dreamstime.com/z/mapa-sat%C3%A9lite-de-new-york-city-ilha-manchattan-ruas-e-centro-da-cidade-vista-vizinhan%C3%A7as-blocos-coloridos-colorido-do-cartaz-eua-143501487.jpg>.

O surgimento desta métrica ocorreu no período em que o pesquisador Herman Minkowski (1894-1909), apresenta a Geometria dos Números e trabalha com formas quadráticas em n variáveis considerando algumas propriedades geométricas em um espaço de n dimensões, este cenário favoreceu para uma estrutura com o uso da Geometria NãoEuclidiana no trabalho da Relatividade de Albert Einstein (Ex-Aluno).


Minkowski reconhece que a geometria euclidiana da distância entre dois pontos em uma linha reta não é necessariamente o melhor modelo para o mundo real, especificamente em cidades onde há quarteirões. Com o objetivo de melhor representar essas distâncias surge a métrica *Taxicab* que passa por períodos de interesse e, também por marginalização e somente em 1975 a geometria urbanista ou taxista é reconhecida pelo professor de matemática da

Universidade de Michigan, Eugene Krause, que publicou um livro intitulado “*Taxicab Geometry: An Adventure Non-Geometry*” (KRAUSE, 1975).

A geometria urbanista é quase a mesma que a geometria de coordenadas euclidianas. Os pontos são os mesmos, as linhas são as mesmas e os ângulos são medidos da mesma maneira. Somente as funções das distâncias são definidas de formas diferentes (KRAUSE, 1975). Na Figura 19 a distância entre os pontos P e Q , é denotada por $d_T(P, Q)$ e é determinada pelas linhas horizontais e verticais, assim tem-se:

$$d_T(P, Q) = 7$$

Figura 19– Geometria Urbana no Espaço Euclidiano.




Fonte: Krause(1975).

Considerando o ponto $P = (x_1, y_1)$ e $Q = (x_2, y_2)$ obtem-se a equação (16) referente à distância de Manhattan:

$$d_T(P, Q) = |x_1 - x_2| + |y_1 - y_2| \quad (16)$$

Quadro 5– Cálculo Euclidiano e NãoEuclidiano.




Fonte: Própria Autora.

Considere, por exemplo, o cálculo da distância euclidiana e distância de Manhattan, entre os pontos $A = (3, 4)$ e $B = (6, 8)$ equidistantes no plano apresentados no Quadro 5.

A representação geométrica da circunferência da geometria euclidiana e nãoeuclidiana, aqui representada pela geometria taxista, está apresentada pelo centro C_E e C_T igual a $(3, 4)$ e os pontos (x, y) das circunferências euclidiana e nãoeuclidiana, representados por $P(x, y)$, com raio de 3 unidades de comprimento. O Quadro 6 ilustra a forma comparativa das figuras geométricas.

Quadro 6– Geometria Euclidiana e Geometria NãoEuclidiana.



Fonte: Própria Autora.


Nesta nova metodologia apresenta-se a equação da distância de Manhattan na função da escolha da categoria para definição do neurônio vencedor na estrutura da rede neural artificial ARTMAP Euclidiana. Assim, ao invés do uso da distância euclidiana, optou-se pela métrica da distância de Manhattan (Táxi ou L_1).

A função da escolha da categoria se encontra na camada de reconhecimento (F_2), onde os padrões de treinamento são classificados em categorias conforme aprendizado da rede neural artificial (CARPENTER *et al.*, 1992).

O neurônio da camada F_2 selecionado como vencedor durante o processamento corresponde a unidade j com menor valor de função de escolha T_j (se houver categorias iguais, escolhe-se a categoria J com $T_j = \min_j\{T_j\}$ e índice J mínimo). A equação de escolha da categoria com uso da distância do Manhattan é definida pela função (16).

$$d_{X(t,m)} = \sum_{k=1}^n |X_{tk} - X_{mk}| \quad (17)$$

Em que X_{tk} equivale aos vetores de entrada (I) e X_{mk} é o vetor peso (w) utilizados no treinamento. A Figura 20 descreve o processo da camada de reconhecimento na fase de aprendizado da rede neural artificial.

Figura 20 – Camada de Reconhecimento (F_2).

Fonte: Própria Autora Adaptado.

Tabela 1–Equações Utilizadas no Treinamento das Redes.


Funções	ARTMAP Euclidiana	ARTMAPde Manhattan
Cálculo da Categoria	$T_j^a = (I_j^a - W_j^a)(I_j^a - W_j^a)^T$	$T_j = I_j^a - W_j^a I_j^a - W_j^a ^T$
Escolha da Categoria	$T_j^a = \min\{T_j: j = 1, \dots, N\}$	$T_j^a = \min\{T_j: j = 1, \dots, N\}$
Teste de Vigilância	$\frac{T_j^a}{\max(I_j^a I_j^{aT}, W_j^a W_j^{aT})} < \rho_a$	$\frac{T_j^a}{\max(I_j^a I_j^{aT}, W_j^a W_j^{aT})} < \rho_a$
Atualização dos Pesos	$W_j^a = \beta(I_j^a) + (1 - \beta)W_j^a$	$W_j^a = \beta(I_j^a) + (1 - \beta)W_j^a$
<i>Match -Tracking</i>	$ y_b \wedge W_j^{ab} < \rho_{ab}$	$ y_b \wedge W_j^{ab} < \rho_{ab}$
Decremento do Parâmetro	$\rho_a = \frac{T_j^a}{\max(I_j^a I_j^{aT}, W_j^a W_j^{aT})} - \varepsilon$	$\rho_a = \frac{T_j^a}{\max(I_j^a I_j^{aT}, W_j^a W_j^{aT})} - \varepsilon$

Fonte: Própria Autora.

A Tabela 1 apresenta a diferença das equações utilizadas para o Cálculo da Categoria no treinamento da rede neural artificial.

A previsão realizada nesta segunda proposta foi organizada como da primeira proposta, ou seja, com a mesma prescrição dos dados. Na Figura 21, é apresentada a esquematização do processo executado pela rede neural ARTMAP Manhattan para as previsões nodais.

Figura 21– Representação do Processo da Previsão.



Fonte: Própria Autora.

O recente modelo de fácil implementação para a escolha de categoria tem como origem e características a rede neural ARTMAP Euclidiana, uma rede inteligente descendente da família das redes da Teoria da Ressonância Adaptativa. Os passos do desenvolvimento da rede neural ARTMAP Manhattan é descrito pelo algoritmo da seguinte forma:

1ª Etapa- Início: Definição do vetor padrão de entrada, pesos e parâmetros.

1º Passo: Leitura dos Padrões de Entrada e Saída com dados originais:

O vetor I_j^a representa o vetor de entrada do módulo ART_a e o vetor I_k^b o vetor de saída desejada do módulo ART_b :

- Vetor de entrada: $I_j^a = [a_1 \ a_2 \ ... \ a_M]$;
- Vetor de saída: $I_k^b = [b_1 \ b_2 \ ... \ b_M]$.

Sendo:

M : dimensão do vetor.

2º Passo: Construção das matrizes de pesos:

Os Pesos W_j^a e W_k^b são iniciados com valor igual a 0, indicando a presença de um único *cluster* (categoria) ativa. O peso W_{jk}^{ab} inicia com o valor igual a 1, indicando que não existe nenhuma categoria ativa.

3º Passo: Leitura dos Parâmetros:

Os parâmetros utilizados para treinamento e teste da rede estão compreendidos entre os valores de zero a um (ficando a critério a quantidade de algarismos):

- β : taxa de treinamento $[0, 1]$;
- ρ_a : parâmetro de vigilância do módulo ART_a $[0, 1]$;
- ρ_b : parâmetro de vigilância do módulo ART_b $[0, 1]$;
- ρ_{ab} : parâmetro de vigilância do módulo ART_{ab} $[0, 1]$;
- ε : decremento do parâmetro ρ_a .

2ª Etapa - Processo de treinamento dos dados do vetor padrão de entrada nos módulos: ART_b Euclidiana e ART_a Euclidiana.

4º Passo: Cálculo das funções T_k^b e T_j^a com o uso da distância de Manhattan.

$$T_k^b = |\mathbf{I}_k^b - \mathbf{W}_k^b| |\mathbf{I}_k^b - \mathbf{W}_k^b|^T \quad (18)$$

$$T_j^a = |\mathbf{I}_j^a - \mathbf{W}_j^a| |\mathbf{I}_j^a - \mathbf{W}_j^a|^T \quad (19)$$

5º Passo: O índice K indica a categoria escolhida.

$$T_K^b = \min\{T_k : k = 1, \dots, N\} \quad (20)$$

6º Passo: O critério de vigilância do módulo ART_b é determinado por meio da equação (21)

$$\frac{T_K^b}{\max(\mathbf{I}_K^b \mathbf{I}_K^{bT}, \mathbf{W}_K^b \mathbf{W}_K^{bT})} < \rho_b \quad (21)$$

7º Passo: Se o critério de vigilância for satisfeito, ocorre a ressonância e passa-se para próximo passo no qual se atualiza o vetor peso $\mathbf{W}_K^b$.

$$\mathbf{W}_K^b = \beta(\mathbf{I}_K^b) + (1 - \beta)\mathbf{W}_K^b \quad (22)$$

8º Passo: Cálculo do vetor atividade para o número de categorias criadas:

$$\mathbf{y}_K^b = [y_1^b \ y_2^b \ \dots \ y_N^b] \quad (23)$$

Para:

$$\mathbf{y} = \begin{cases} y_k^b = 0, & \text{se } k \neq K \\ y_k^b = 1, & \text{se } k = K \end{cases} \quad (24)$$

9º Passo: Se o critério de vigilância não for satisfeito, então não houve ressonância e faz-se $T_K^b = 0$ e ocorre o *reset*.

O módulo ART_a possui a mesma estrutura e a característica do módulo ART_b usada anteriormente. Porém, a atualização de $\mathbf{W}_j^a$ e vetor atividade $\mathbf{y}_j^a$, será realizada somente depois do módulo *Inter-ART*, logo após a análise realizada pelo *Match-Tracking*. Na última etapa deste módulo, verifica-se se há o “casamento” da entrada de ART_a com a saída de ART_b . (GOMES, 2017).

3ª Etapa - Finalizando este módulo, averigua-se se houve o “casamento” entre os Módulo ART_a e Módulo ART_b .

10º Passo: O critério de vigilância no módulo *Inter-ART* é verificado por meio da equação (25):

$$|\mathbf{y}_j^b \wedge \mathbf{W}_j^{ab}| > \rho_{ab} \quad (25)$$

11º Passo: Vetor atividade do Módulo ART_a é descrito pela equação (26).

$$\mathbf{y}_j^a = [y_1^a \ y_2^a \ \dots \ y_N^a] \quad (26)$$

Para:

$$\mathbf{y} = \begin{cases} y_j^a = 0, & \text{se } j \neq J \\ y_j^a = 1, & \text{se } j = J \end{cases} \quad (27)$$

12º Passo: Atualização do vetor de pesos $\mathbf{W}_j^a$:

$$\mathbf{W}_j^a = \beta(\mathbf{I}_j^a) + (1 - \beta)\mathbf{W}_j^a \quad (28)$$

13º Passo: Atualização do vetor de pesos $\mathbf{W}_{JK}^{ab}$:

$$\mathbf{W}_{JK}^{ab} = [y_1^{ab} \ y_2^{ab} \ \dots \ y_N^{ab}] \quad (29)$$

Para:

$$y_{jk}^{ab} = \begin{cases} 0, & \text{se } j = J; k \neq K \\ 1, & \text{se } j = J; k = K \end{cases} \quad (30)$$

14º Passo: Se não ocorre ressonância no módulo Inter-ART é acrescentado um decremento no parâmetro de vigilância conforme equação (31).


$$\rho_a = \frac{T_j^a}{\max(\mathbf{I}_j^a \mathbf{I}_j^{aT}, \mathbf{W}_j^a \mathbf{W}_j^{aT})} - \varepsilon \quad (31)$$

15º Passo: E volta para a escolha do índice J indicando a categoria escolhida.

$$T_j^a = \min\{T_j; j = 1, \dots, N\} \quad (32)$$

Este procedimento termina quando a categoria escolhida (vencedora) selecionada atenda (satisfaça) o teste de vigilância. O fluxograma do algoritmo mantém as mesmas peculiaridades do fluxograma da rede neural artificial ARTMAP Euclidiana com somente a troca das equações da distância euclidiana para a distância de Manhattan. O fluxograma da rede ARTMAP Manhattan está apresentado na Figura 22.

Figura 22 – Fluxograma ARTMAP Manhattan.



Fonte: Própria Autora

8 RESULTADOS

Os resultados, aqui apresentados, de forma numérica e gráfica, foram realizados por meio de simulações computacionais com o uso do modelo de treinamento reverso (AMORIM *et al.*, 2020) com utilização da rede neural artificial ARTMAP Euclidiana para a obtenção das previsões das cargas elétricas multinodais e a segunda proposta com o uso da distância de Manhattan na camada de reconhecimento da rede neural.

O conjunto de dados utilizados nas fases de treinamento e teste para duas metodologias propostas foram cedidos pelo Setor Elétrico de Nova Zelândia. Para simulação do treinamento utilizou-se 31 dias, (08 de dezembro de 2008 a 08 de janeiro de 2009) para prever o dia 09 de janeiro de 2009. O banco de dados utilizados fornece dados históricos de cargas elétricas em intervalos de meia hora e, portanto para 24 horas tem-se um vetor que corresponde a uma amostra de 48 pontos.

Como a fase de treinamento possui informações correspondentes a 31 dias, então o conjunto de dados utilizados terá um vetor que corresponde a 1488 pontos. Da mesma forma, como a saída da rede neural refere-se a previsão do dia seguinte (24 horas) tem-se um vetor de saída que corresponde a 48 pontos. Estes conjuntos são utilizados com a mesma estrutura para a realização das previsões de cargas globais multinodais. Na Tabela 2 são apresentados os períodos utilizados nas simulações nas fases de treinamento e previsão.

Tabela 2 – Dados Coletados.

Banco de Dados	Período (dia/mês/ano)	Quantidade de pontos
Treinamento	08/12/2008 a 08/01/2009	1488
Previsão	09/01/2009	48

Fonte: Própria Autora.

O banco de dados fornecidos pela Nova Zelândia incluía também outros tipos de dados exógenos tais como: horário de verão, temperatura mínima e máxima, magnitude da intensidade solar, etc.. Ressalta-se que estas informações não foram utilizadas neste trabalho, porém pode-se futuramente estudar o impacto destas variáveis aplicada ao problema de previsão de demanda. No Quadro 7, apresenta-se uma pequena amostra dos dados originais fornecidos para a pesquisa.

Quadro 7 – Dados Originais.

Data	Amostra(1/2h)	Classe do dia	Horário de Verão	Solar Azimuth	Solar Altitude	Tmax	Tmin	Kopu	Waikino	Wailhou	Hamilton 11KV	Hamilton 33KV	Cambridge	Te Awamutu (W. Hinuera	Kinleith	Total [KW]
1/1/2008	1	40	1	-162.75	-23.65	27.7	9.5	23104	19412	31194	9940.0	40376.0	13266.0	11518.0	13466.0	73710
1/1/2008	2	40	1	-170.18	-24.97	27.7	9.5	22852	18762	29982	9528.0	38744.0	13732.0	10718.0	13082.0	71596
1/1/2008	3	40	1	177.77	-25.57	27.7	9.5	21192	17452	28878	8964.0	37398.0	12694.0	9496.0	12470.0	67522
1/1/2008	4	40	1	174.59	-25.41	27.7	9.5	19198	16276	28068	8560.0	35708.0	12448.0	8780.0	11876.0	63542
1/1/2008	5	40	1	167.05	-24.51	27.7	9.5	17538	15330	27450	8292.0	34248.0	11956.0	8424.0	11790.0	60318

Fonte: Própria Autora.

Na construção da base de dados utilizada nas simulações tem-se os dias da semana e o horários representados de formabinária e as cargas elétricas em forma de janelamento, como mostrado anteriormente. No Quadro 8, apresenta-se, de maneira simplificada, a amostragem das informações do banco de dados.

Quadro 8 – Dados para Treinamento.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q
1	0	0	0	0	0	0	0	0	0	159854	157331	154808	196072	181668	169144	159854	154808
2	0	0	1	0	0	0	0	0	1	154808	153157	151506	181668	169144	159854	154808	151506
3	0	0	1	0	0	0	0	0	1	151506	150592	149678	169144	159854	154808	151506	149678
4	0	0	1	0	0	0	0	0	1	149678	148945	148212	159854	154808	151506	149678	148212
5	0	0	1	0	0	0	0	1	0	148212	147136	146060	154808	151506	149678	148212	146060

Fonte: Própria Autora.

Vale destacar que, neste banco de dados, não há recuperação e nem a substituição de informações faltantes, ou de dados com anormalidades. Portanto, não houve nenhum tipo de pré-processamento, ou uso de algum modelo ou desenvolvimento de filtro para as cargas elétricas. Esse procedimento, também, ocorre quando se realiza a previsão das cargas multinodais.

Então, o banco de dados utilizados na fase de treinamento contém as informações dos dados exógenos (horário, dias da semana, carga máxima, carga mínima e carga média) juntamente com as cargas elétricas com um deslocamento de 5 janelas, sendo três cargas anteriores a carga atual e a carga subsequente.

A previsão de cargas multinodais também mantém as mesmas características para a simulação.

As métricas utilizadas para apresentação dos resultados desta pesquisa foram MAPE (Erro Percentual Absoluto Médio) (PARK *et al.*, 1991), Emáx. (Erro Máximo Percentual), Emín. (Erro Mínimo Percentual) (SRINIVASAN *et al.*, 1998), MAE (Erro Médio Absoluto), e RMSE (*Root Mean Square Error*) (SHAHRABI *et al.*, 2013, YANG *et al.*, 2016), com intensão de comensurar e examinar o desempenho da metodologia idealizada. Na Tabela 3, são apresentadas as métricas utilizadas na pesquisadas pelas equações (33), (34), (35), (36) e (37).

Tabela 3 – Métricas Utilizadas na Análise de Desempenho da Metodologia.

MÉTRICAS DE AVALIAÇÃO	
$MAPE = \frac{1}{N_e} \sum_{i=1}^{N_e} \left \frac{C_{real}(h) - C_{prevista}(h)}{C_{real}(h)} \right \cdot 100 \text{ (PARK et al., 1991)}$	(33)
$Emáx. = máx \left\{ \frac{ C_{real}(h) - C_{prevista}(h) }{C_{real}(h)} \right\} \cdot 100$	(34)
$Emín. = mín \left\{ \frac{ C_{real}(h) - C_{prevista}(h) }{C_{real}(h)} \right\} \cdot 100$	(35)
$MAE = \frac{1}{N_e} \sum_{i=1}^{N_e} C_{real}(h) - C_{prevista}(h) \text{ (SHAHRABI et al., 2013)}$	(36)
$RMSE = \sqrt{\frac{1}{N_e} \sum_{i=1}^{N_e} (C_{real}(h) - C_{prevista}(h))^2}$	(37)

Fonte: Própria Autora.

Sendo:

 N_e : número de amostras da série temporal; $C_{real}(h)$: carga elétrica real no instante h ; $C_{prevista}(h)$: carga elétrica prevista no instante h .

Para a realização das simulações utilizou-se o software MATLAB R2015b (Matrix Laboratory), uma ferramenta computacional de linguagem de programação favorável para os cálculos com matrizes de grandes dimensões.

8.1 RESULTADO DA PREVISÃO GLOBAL

A pesquisa realizada é composta por duas etapas, realiza-se a previsão global das cargas elétricas com o sistema predictor global e a previsão local de cargas elétricas com o

sistema previsor multimodal, empregando os dados das nove subestações da Nova Zelândia. O algoritmo utilizado para as simulações foi a rede neural ARTMAP Euclidiana para o treinamento global (clássico) e rede neural ARTMAP Euclidiana com treinamento reverso para o treinamento multinodal. Visando um resultado eficiente em todas as previsões, exploram-se valores para os parâmetros da rede neural, a fim de encontrar o valor mais preciso para um resultado suficientemente próximo do real. Na Tabela 4, apresentam-se os valores dos parâmetros utilizados no processamento do treinamento global.

Tabela 4 – Parâmetros da Rede Neural ARTMAP Euclidiana.

Parâmetros	β	ρ_a	ρ_b	ρ_{ab}	ε
Valores	0,9999	0,0000001	0,0000001	0,0000001	0,000001

Fonte: Própria Autora.

O parâmetro de vigilância (ρ_a) utilizado para o módulo de Previsão Global tem o valor de 0,01.

O resultado numérico obtido e o tempo de processamento da Previsão Global utilizando o sistema previsor global, com base nas métricas, estão relacionados na Tabela 5. Observando os valores obtidos pelas métricas observa-se que os resultados são considerados satisfatórios em relação à literatura destinada previsão global, ou seja, a soma como um todo, neste contexto, a soma das nove subestações. Neste treinamento foram ativados 837 neurônios.

Tabela 5 – Métricas Obtidas para o Sistema Previsor Global.

Métricas	MAPE	Emáx.	Emín.	MAE	RMSE	Tempo (s)
Valores	1,2673	5,6784	0,0031	0,0127	8,8446	54,9214


Fonte: Própria Autora.

Na tabela 5 tem-se que o MAPE obtido é considerado baixo indicando que o erro percentual médio foi de aproximadamente 1,2673%. O MAE e RMSE são medidas que analisam basicamente a média entre os valores de cargas reais e previstos e, portanto, possuem uma unidade (dimensão), igual à dimensão dos valores de cargas reais e previstos. O MAE obtido indica que em média a metodologia utilizada pode estar errando 0,0127 MW para acima ou para baixo em relação ao valor exato. Analisando o valor tem-se que este não representa um erro grande. O RMSE é considerado o desvio padrão dos erros e, como os erros são quadráticos tem-se que o RMSE é sensível a valores discrepantes (*outliers*). O RMSE

obtido indica que o modelo utilizado pode estar errando 8,8446 MW para mais ou para menos. O valor obtido para o RMSE não é considerado grande.

A Figura 23 apresenta o resultado da Previsão Global em um horizonte de 24 horas. A linha azul representa a curva de demanda da carga elétrica global real e a linha vermelha representa a carga elétrica global prevista.

Figura 23 – Representação Gráfica da Previsão Global.



Fonte: Própria Autora.

Observando as curvas, real e prevista, constata-se a eficiência da rede neural ARTMAP Euclidiana, uma vez que as curvas aproximam-se uma da outra, diferenciando apenas em alguns pontos.

8.2 RESULTADOS DAS PREVISÕES MULTINODAIS COM TREINAMENTO REVERSO

Na sequência, são apresentadas as realizações da previsão da carga multinodal das nove subestações. Observou-se que não houve alterações significativas nos resultados com o uso de diferentes valores para os parâmetros de vigilância ($\rho_a, \rho_b, \rho_{ba}$). Neste caso, os valores dos parâmetros, $\rho_a, \rho_b, \rho_{ba}$, utilizados foram 0,0000001. Porém, a taxa de treinamento (β) utilizada no ambiente do treinamento reverso recebeu valores variados, ou seja, as previsões das subestações obtiveram em seu treinamento valores distintos da taxa de treinamento.

Na Tabela 6, são apresentados os parâmetros utilizados pela rede neural artificial ARTMAP Euclidiana com treinamento reverso.

Tabela 6 – Parâmetro de Treinamento da ARTMAP Euclidiana com Treinamento Reverso.

Subestação	Taxa (β)	Subestação	Taxa (β)
Kopu	0,999999	Waihou	0,990000
Cambridge	0,999999	Waikino	0,999999
Hamilton 11kV	0,970000	Te Awamutu	0,999990
Hamilton 33kV	0,999900	Kinleith	0,999990
Hinuera	0,890000		

Fonte: Própria Autora.

De fato, é notório as diferenças entre as subestações em virtude das circunstâncias geográficas e das características da região localizadas no norte de Nova Zelândia. Outro motivo se dá pelo desafio da previsão de cargas elétricas a um nível mais reduzido (como por exemplo, as subestações) tornando favorável para investigações com grau de maior profundamento nas pesquisas. Na Tabela 7 está exposto os resultados das métricas obtidas para as previsões elétricas multinodais das subestações estudadas nesta pesquisa.


Tabela 7 – Métricas Obtidas para o Sistema Previsor Local.



Subestações	MAPE	Emáx.	Emín.	MAE	RMSE	Tempo (s)
Kopu	8,1303	21,6326	0,0059	0,0813	20,1920	1,02854
Cambridge	3,2655	8,7886	0,0230	0,0327	7,3124	1,05269
Hamilton 11	2,9932	13,3735	0,0216	0,0300	8,7239	1,02546
Hamilton 33	2,9058	11,0472	0,2077	0,0290	8,4162	1,05968
Hinuera	8,1188	16,9231	0,3052	0,0811	19,8721	1,05298
Waihou	3,7760	10,8785	0,0002	0,0378	14,0369	1,07466
Waikino	10,3352	28,1492	0,2518	0,1033	22,2696	1,11373
Te Awamutu	3,6669	17,1306	0,0895	0,03666	13,7631	1,10897
Kinleith	7,6239	26,9556	0,0001	0,0762	15,4492	1,14178

Fonte: Própria Autora.

Os resultados apresentados graficamente, ilustram o comportamento das curvas realizadas pelas previsões das cargas elétricas multinodais no uso da ARTMAP Euclidiana com treinamento reverso. A linha azul (—▲—) representa a carga elétrica multinodal real e a linha verde (—▲—) a carga elétrica multinodal prevista. O gráfico contempla intervalos de tempo de 30 min, totalizando 48 pontos, correspondendo a um período de 24h. A Figura 24 apresenta o conjunto dos gráficos das previsões multinodais.

Figura 24 – Conjunto de Gráficos das Previsões Multinodais.









Gráfico do Sistema Previsor Local - Waikino






Gráfico do Sistema Previsor Local - Te Awamutu





Ao analisar os resultados da metodologia verifica-se que as subestações Cambridge, Hamilton 11kV, Hamilton 33kV, Waihoou e Te Awamutu obtiveram valores inferiores ao erro percentual de 5%, considerado aceitável pelo setor energético. Contudo as demais subestações Kopu, Hinuera, Waikino e Kinleith, não obtiveram desempenho favorável quanto ao erro percentual ficando com valores superiores do esperado.

8.3 RESULTADO DA PREVISÃO GLOBAL -ARTMAP MANHATTAN

Esta segunda metodologia é um recente modelo para previsão de cargas com a utilização da métrica distância de Manhattan, uma formulação para facilitar no treinamento de dados na escolha do melhor neurônio vencedor que fornece resultados satisfatórios para previsão das cargas elétricas das subestações. Este processo não utiliza nenhuma informação de outras subestações, assim é realizado de forma única, ou seja, de maneira independente das informações de qualquer outra subestação. Sendo assim, não se faz o uso do fator de participação e nenhum tipo de técnica de filtragem e processamento dos dados originais. Esta metodologia se caracteriza de forma primitiva, ou seja, sua estrutura está baseada na estrutura da arquitetura da Teoria da Ressonância Adaptativa.

O conjunto de dados de entrada e saída utilizados nas fases de treinamento e diagnóstico está definido da seguinte forma (LOPES, MINUSSI, LOTUFO, 2005):

$$A(h) = [t \ C(h-3) \ C(h-2) \ C(h-1) \ C(h)], \quad X \in \mathfrak{R}^m \quad (38)$$

$$B(h) = [C(h + 1)], \quad Y \in \mathbb{R}^1 \quad (39)$$

Em que:

- t : vetor de tempo respectivo aos dados históricos (dados exógenos);
 $C(h - q)$: valor da carga q instantes, antecedente a carga elétrica no instante h ;
 $C(h + 1)$: valor da carga referente ao instante subsequente à carga no instante h ;
 h : instante retratado a meia hora.

A Tabela 8 apresenta os valores da taxa de treinamento, parâmetros de vigilância e decremento ao parâmetro de vigilância utilizados no treinamento clássico da rede.

Tabela 8– Parâmetros Utilizado na Rede ARTMAP Manhattan.

Parâmetros	β	ρ_a	ρ_b	ρ_{ab}	ε
Valores	0,99999	0,0000001	0,0000001	0,0000001	0,000001

Fonte: Própria Autora.

A Tabela 9 apresenta as métricas calculadas para os resultados obtidos para a previsão global.


Tabela 9 – Métricas Obtidas para o Sistema Previsor Global com ARTMAP Manhattan.

Métricas	MAPE	Emáx.	Emín.	MAE	RMSE	Tempo (s)
Valores	1,0173	4,8520	0,0032	0,0101	7,6808	55,14876

Fonte: Própria Autora.

Através da Tabela 9 observa-se um MAPE de 1,0173% que é um erro relativamente baixo que indica um modelo bem ajustado a curva de carga real. O MAE obtido foi em média de 234,86 MW para acima ou para baixo em relação ao valor de carga real e RMSE foi em média 334,29 MW para mais ou para menos. A Figura 25 mostra o comportamento das curvas da carga global real na linha azul e em vermelho a previsão da carga global, com intervalos de 30 a 30 min, totalizando 48 pontos.

Figura 25 – Representação Gráfica da Previsão Global de Manhattan.



Fonte: Própria Autora.

Analisando as linhas das curvas do gráfico, a carga real e a carga prevista mantêm o mesmo comportamento, diferenciando no início (primeiras meia-hora do dia) e na metade do dia (período do meio-dia). A metodologia com uso da distância de Manhattan mostra-se uma proposta confiável. Comparando os resultados de previsão global obtidos pela redes neurais ARTMAP Manhattan e ARTMAP Euclidiana é possível notar que o recente modelo é capaz de fornecer melhores previsões em relação a previsão global.

8.4 RESULTADOS DAS PREVISÕES NODAIS - ARTMAP DE MANHATTAN

As simulações realizadas utilizam parâmetros como: taxa de treinamento (β), parâmetros de vigilância nos módulos $ART_a(\rho_a)$, $ART_b(\rho_{ab})$ e $Inter - ART(\rho_{ab})$. Na etapa do treinamento observou-se que a rede neural fornecia os mesmos valores em relação as métricas usando os mesmos valores dos parâmetros de vigilância ($\rho_a, \rho_b, \rho_{ab}$) com valor de 0,0000001 e a taxa do decremento com valor igual a 0,000001. Os resultados sofriam alteração apenas quando os valores da taxa de treinamento eram modificados.

A Tabela 10 apresenta somente os valores do parâmetro da Taxa de Treinamento utilizados na rede para a realização das Previsões Nodais.

Tabela 10 – Valores dos Parâmetros da ARTMAPManhattan.

Subestação	Taxa (β)	Subestação	Taxa (β)
Kopu	0,999990	Waihou	0,990000
Cambridge	0,999990	Waikino	0,999000
Hamilton 11kV	0,990000	Te Awamutu	0,999999
Hamilton 33kV	0,999000	Kinleith	0,999000
Hinuera	0,999000		

Fonte: Própria Autora.

A Tabela 11 mostra os resultados obtidos com o uso da métrica da distância de Manhattan no cálculo da função escolha da categoria.

Tabela 11 – Métricas Obtidas Utilizando a Rede ARTMAP Manhattan.

Subestações	MAPE	Emáx.	Emín.	MAE	RMSE	Tempo (s)
Kopu	1,2259	6,6199	1,0000	0,0122	5,1106	56,86755
Cambridge	1,9853	7,8123	0,0336	0,0198	4,6561	53,99378
Hamilton 11	2,1332	8,2815	0,0648	0,0213	5,2775	57,33041
Hamilton 33	1,4622	7,4498	0,0207	0,0146	4,9858	56,72722
Hinuera	2,0908	5,6397	0,0100	0,02090	3,8373	55,63819
Waihou	1,9336	7,1362	0,0590	0,0193	5,9194	56,28200
Waikino	2,7902	12,6817	0,0228	0,0279	6,3234	55,73120
Te Awamutu	2,3944	14,1747	0,1138	0,0239	4,8999	58,08900
Kinleith	5,7699	25,0409	0,6740	0,0576	7,3501	59,11513


Fonte: Própria Autora.

Os valores dos resultados obtidos pelas métricas para medir o desempenho da rede prova que o modelo proposto com o uso da equação da distância de Manhattan para cálculo da escolha da categoria faz-se satisfatório para realização da proposta de previsões nodais.

As Figuras 26 a 34 apresentam o conjunto dos resultados gráficos das previsões nodais. Os resultados apresentados ilustram o comportamento das curvas realizadas pelas previsões das cargas elétricas das subestações com o uso da ARTMAP Manhattan. A linha azul (←→)


representa a carga elétrica real das subestações e a linha verde (—○—) a carga elétrica prevista das subestações. Os gráficos contém intervalos de 30 em 30 minutos, totalizando 48 pontos, correspondente a um período de 24h.

Figura 26 – Previsão da Subestação Kopu.




Fonte: Própria Autora.

Figura 27 – Previsão da Subestação Cambridge.




Fonte: Própria Autora.

Figura 28 – Previsão da Subestação Hamilton 11kV.




Fonte: Própria Autora.

Figura 29 – Previsão da Subestação Hamilton 33kV.




Fonte: Própria Autora.

Figura 30 – Previsão da Subestação Hinuera.




Fonte: Própria Autora.

Figura 31 – Previsão da Subestação Waihou.




Fonte: Própria Autora.

Figura 32 – Previsão da Subestação Waikino.




Fonte: Própria Autora.

Figura 33 – Previsão da Subestação Te Awamutu.



Fonte: Própria Autora.

Figura 34 – Previsão da Subestação Kinleith.



Fonte: Própria Autora.

Ao analisar os gráficos das nove subestações, observa-se que a linha (em verde) da carga prevista apresenta um comportamento que acompanha a linha (em azul) da carga real. Diante dos resultados, considerando-se as métricas definidas na Tabela 3, é possível constatar que a capacidade preditiva da rede neural ARTMAP Manhattan é muito boa apresentando erros percentuais médios com valores bem abaixo de 5%. Esta arquitetura forneceu previsões precisas e suaves e desta forma garante a confiabilidade de seu uso.

9 CONCLUSÃO E SUGESTÕES PARA PESQUISAS FUTURAS

9.1 CONCLUSÃO

Nesta pesquisa, optou-se por um processo mais robusto e sem técnicas de filtragem ou modelos de aperfeiçoamento de dados de entrada para realização das Previsões des Cargas Globais, Multinodais e Nodais com testes realizados por meio das metodologias propostas com uso das redes neurais ARTMAP Euclidiana com Treiamento Reverso e ARTMAP Manhattan. Evidentemente, com a implantação de filtragem etc, espera-se um melhor desempenho.

A série de dados foram cedidos por *New Zealand Electricity Commission* e extraídos do *Centralized dataset* em 2010. Foram utilizados informações referentes ao dia, mês, ano e as cargas elétricas medidas de meia em meia hora, totalizando 1488 pontos para fase de treinamento e 48 pontos (24 horas) para fase de diagnóstico (previsão).

Fatores externos podem ocasionar flutuação das cargas elétricas. Neste sentido, trazem desafios aos sistemas previsores. Contudo, os modelos de redes neurais artificiais permitem que os testes realizados proporcionam resultados mais assertivos. A rede neural ARTMAP Euclidiana possui uma grande superioridade pelo fato de serem implementadas com facilidade e pelas características das redes da família da Teoria da Ressonancia Adaptativa, plasticidade e estabilidade, capacidade da rede aprender novas informações sem que se perca os conhecimentos já adquiridos e se mantendo estável. Considerando as mesmas características surge o recente modelo batizado com o nome de ARTMAP Manhattan utilizando a métrica da distância de Manhattan.

A primeira metodologia desenvolvida com treinamento reverso apresenta um modelo que faz o uso do fator de participação, uma ferramenta apta para introduzir o conjunto de informações e características das subestações. Este processo é viável para a previsão da carga elétrica multinodal, utilizada em pontos ou barramentos do sistema elétrico. Em uma visão ampla este conceito é valido para sistemas interligados, sendo a operação complexa e sob o controle de órgãos e empresas responsáveis pela manutenção, aja vista, que áreas isoladas necessitam de energia elétrica. Neste cenário, é imprescindível planejamento para sistemas isolados. Desde modo, a segunda proposta é promissora oferecendo resultados convenientes para previsões locais em regiões longínquas.

Os testes foram realizados pela rede neural ARTMAP Euclidiana com treinamento reverso, e apesar dos atributos da rede ARTMAP Euclidiana ter compatibilidade e pertencer a

família da Teoria da Ressonância Adaptativa, a obtenção dos resultados das avaliações métricas constituem uma variação não tão aceitáveis, pois registrou com MAPE inferior a 5%, apenas as subestações: Cambridge, Hamilton 11kV, Hamilton 33kV, Waihou e Te Awamutu e com valor superior a 5% as subestações: Kopu, Hinuera, Waikino e Kinleith. Ao observar os gráficos é possível verificar pontos destoantes como mostra a plotagem das subestações Kopu, Hinuera e Kinleith, porém a subestação Waikino extrapola no distanciamento no comportamento da curva.

A contribuição da segunda proposta mostra o impacto positivo da rede neural ARTMAP Manhattan, o modelo utilizado no sistema predictor com base na arquitetura da família da Teoria da Ressonância Adaptativa revela todo o potencial da rede neural ao equacionar a competitividade dos neurônios vencedores com o uso da distância de Manhattan. A flexibilidade da rede disponibilizou previsões de oito subestações certificando erros inferiores a 3%. As curvas das cargas previstas apresentam assertividade na suavização em relação a plotagem. Os testes da segunda metodologia expressam que a rede ARTMAP Manhattan prova segurança e eficiência garantindo previsões de cargas elétricas para subestações ou sistemas isolados do setor elétrico.

9.2 SUGESTÕES PARA PESQUISAS FUTURAS

O recente trabalho fez uso de um processo robusto na utilização dos dados e também no uso das redes neurais: ARTMAP Euclidiana com Treinamento Reverso e ARTMAP Manhattan. A obtenção dos resultados são satisfatórias em relação ao que o setor elétrico determina, em consideração ao ambiente de estudo, o conjunto das subestações, ou seja, as metodologias propostas são capazes de apresentar ótimos resultados. Contudo, sugere-se a continuação da investigação:

- Estudo aprofundado no uso do banco de dados para os testes;
- Análise criteriosa na escolha do período e da quantidade dos dados;
- Uso de variáveis exógenas como temperatura, umidade do ar, velocidade do vento etc;
- Retirada de dados duvidosos (dias atípicos) com uso de filtros ou pré-processamento nos dados;
- Dispor do decremento no módulo ART_b no Treinamento Reverso e a realização do Treinamento Reverso com a ARTMAP Manhattan;

- Explorar outros equacionamentos na escolha da categoria para o treinamento reverso e direto;
- Realizar novas previsões de cargas elétricas com dados provenientes de fontes renováveis, como a eólica, solar, etc.;
- Utilizar as metodologias propostas para estimar o consumo de cargas a outros níveis, por exemplo, para transformadores e alimentadores.

REFERÊNCIAS

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.

ABREU, T.; AMORIM, J. A.; SANTOS-JUNIOR, R. C.; LOTUFO, A. D. P.; MINUSSI, R. C. Multinodal load forecasting for distribution systems using a fuzzy-artmap neural network. **Applied Soft Computing**, Amsterdam, v. 71, p. 307-316, 2018.
<https://doi.org/10.1016/j.asoc.2018.06.039>.

AHA, D. W.; KIBLER, D.; ALBERT, M. K. **Instance-Based Learning Algoritmos, Machine Learning**. Boston: Kluwer Academic Publishers, 1991. v. 6.

ALTRAN, A. B.; LOTUFO, A. D. P.; LOPES, M. L. M. and MINUSSI, C. R. Previsão de carga multinodal em sistemas elétricos de potência usando uma rede neural de base radial. *In: LATIN-AMERICAN CONGRESS ON ELECTRICITY GENERATION AND TRANSMISSION*, 8th, Ubatuba. **Anais [...]** Ubatuba: [s. n.], 2009. p.18-22.

ALTRAN, A. B., MINUSSI, C. R., LOPES, M. L. M., CHAVARETTE, F. R., PERUZZI, N. J. PERUZZI, Multinodal Load Forecasting in Power Electric Systems using a Neural Network with Radial Basis Function”. **Advanced Materials Research**, Baech, v. 217-218, p. 39-44, 2011. DOI: <https://doi.org/10.4028/www.scientific.net/AMR.217-218.39>.

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.

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.

AMORIM A. J.; ABREU T. A.; TONELLI-NETO M.S.; MINUSSI C. R. A new formulation of multinodal short-term load forecasting based on adaptive resonance theory with reverse training, **Electric Power Systems Research**, Amsterdam, v. 179, p. 106096, 2020. DOI: <https://doi.org/10.1016/j.epsr.2019.106096>.

AMORIM, D. G. **Redes ART com categorias internas de geometria irregular**. Tese (Doutorado em Física) - Universidade de Santiago de Compostela, Santiago de Compostela, 2006.

ANDRIOPOULOS, N.; MAGKLARAS, A.; BIRBAS, A.; PAPALEXOPOULOS, A.; VALOUXIS, C.; DASKALKI, S.; BIRBAS, M.; HOUSOS, E.; PAPAIOANNOU, G. P. Short Term Electric Load Forecasting Based on Data Transformation and Statistical Machine Learning., Term Electric Load Forecasting Based on Data Transformation and Statistical Machine Learning. **Appl. Sci.**, Bucharest, v. 11, p. 158, 2021. DOI: <https://dx.doi.org/10.3390/app11010158>.

BAO, J. **Short-term load forecasting based on neural network and moving average**. Iowa: Technical report, Iowa State University, 2002. Disponível em: <http://citeseerx.ist.psu.edu>. Acesso em: 20 out. 2021.

BOX, G. E., JENKINS, G. M. **Times series analysis: forecasting and control**. holden-day. [S. l.: s. n.], 1976.

CARPENTER, G. A.; GROSSBERG, S. The ART of adaptive pattern recognition by a self-organizing neural network. **Computer**, Prague, v. 21, n. 3, p. 77-88, 1988. DOI: <https://doi.org/10.1109/2.33>.

CARPENTER, G.; GROSSBERG, S.; ROSEN, D. B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. neural networks. **Neural Networks**, Oxford, v.4, n.6, p. 759-771, 1991.

CARPENTER G., GROSSBERG S., MARKUZON N., REYNOLDS J., ROSEN D.B., Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Trans. Neural Networks**, Piscataway, v. 3, p. 698-713, 1992.

CARVALHO, T. S.; SANTIAGO, F. S.; PEROBELLI, F. S. Mudanças demográficas no Brasil e seus impactos sobre as emissões de gases de efeito estufa: uma análise de insumo-produto. **Economia Agrícola e do Meio Ambiente**, [s. l.], 2010.

DJUKANOVIC, M., RUZIC, S., BABIC, B., SOBAJIC, D. J., PAO, Y-H, A neural-net based short term load forecasting using moving window procedure, **Electrical Power & Energy Systems**, London, v. 17, n. 6, p. 391, 1995. Elsevier Science Ltd Printed in Great Britain. DOI: [https://doi.org/10.1016/0142-0615\(94\)00009-3](https://doi.org/10.1016/0142-0615(94)00009-3).

DUDEK, G. Neural networks for pattern-based short-term load forecasting: a comparative study. **Neurocomputing**, Libertyville, v. 205, p. 64-74, 2016.

EHRlich P.R. **The Population Bomb**. New York: Ballantine, 1968.

EMPRESA DE PESQUISA ENERGÉTICA – EPE. Atlas da Eficiência Energética Brasil. [S. l.], 2020. Relatório de Indicadores.

GAO, X.; LI, G. A KNN Model Based on Manhattan Distance to Identify the SNARE Proteins. **IEEE Access**, New York, Special Section on Feature Representation and Learning Methods with Applications in Large-Scale Biological Sequence Analysis, v. 8, p. 112922-112931, 2020. DOI:<https://doi.org/10.1109/ACCESS.2020.3003086>.

GHULAM, H.; KHURRAM, S. A.; IMRAN, K. **Electric load forecasting based on deep learning and optimized by heuristic algorithm in smart grid**. New York: Elsevier, 2020. Disponível em: www.elsevier.com/locate/apenergy. Acesso em: 20 out. 2021.

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

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.

GROSS, G.; GALIANA, F. D., Short-Term load forecasting. **Proceedings of the IEEE**, New York, v. 75, n. 12, p. 1558-1573, 1987. DOI: 10.1109/PROC.1987.13927.

GROSSBERG, S. Adaptive pattern recognition and universal encoding ii: feedback, expectation, olfaction, and illusions. **Biological Cybernetics**, Heidelberg, v. 23, p. 187-202, 1976.

GROSSBERG, S. Competitive learning: From interactive activation to adaptive resonance. *Wayback Machine*, **Cognitive Science**, v. 11, n. 1, p. 23-63, 1987.

GROSSMANN, A.; MORLET, J. Decomposition of hardy functions into square integrable wavelets of constant shape. **Journal on Mathematical Analysis**, Philadelphia, v. 15, n.4, p. 723-736, 1984.

HAFEEZ, G.; ALIMGEER, K. S.; KHAM, I. Electric load forecasting based on deep learning and optimized by heuristic algorithm in smart grid. **Applied Energy**, 2020, DOI: <https://doi.org/10.1016/j.apenergy.2020.114915>.

HAYKIN, S. **Neural networks: a comprehensive foundation**. 2. Ed. New Jersey: Prentice Hall, 1999. 842p.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. Ed. Porto Alegre: Bookman, 2001. 900 f.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural Computation**, Cambridge, v. 9, n. 8, p. 1735-1780, 1997.

JARNDAL, A.; HUSAIN, S., Forecasting of Electric Peak Load Using ANN-Cascaded, ANN-NARX and GPR Techniques, 978-1-7281-7315-3/20/\$31.00 ©2020 IEEE, <https://doi.org/10.1109/CCCI49893.2020.9256555>.

KARTALOPOULOS, S. V. **Understanding neural networks and fuzzy logic**: Basic concepts and applications. Piscataway: Wiley, 1997.

KENAYA, R.; CHEOK, K. C. Euclidean ARTMAP Based Target Tracking Control System. In: IEEE INTERNATIONAL CONFERENCE ON ELECTRO/INFORMATION TECHNOLOGY IEEE, 2008, Ames. **Proceedings** [...] New York: IEEE, 2008. DOI: <https://doi.org/10.1109/EIT.2008.4554265>.

KHATOON S., IBRAHEEM, AK SINGH, PRITI, Effects of Various Factors on Electric Load Forecasting: An Overview. In: IEEE POWER INDIA INTERNATIONAL CONFERENCE, PIICON, 6, 2014, Delhi. **Proceedings** [...] Delhi: [s. n.], 2014. DOI: <https://doi.org/10.1109/POWERI.2014.7117763>.

KRAUSE, E. **Taxicab geomtry**: an adventure in non-Euclidean Geometry. Nova York: Dover, 1975.

LI, Y.; ZHANG, S.; HU, R.; LU, N. **A meta-learning based distribution system load forecasting model selection framework**. New York: Elsevier, 2021. DOI: <https://doi.org/10.1016/j.apenergy.2021.116991>.

LIN, J. K.; TSO, S. K.; HO, H. K.; MAK, C. M.; YUNG, K. M.; HO, Y. K. Study of climatic effects on peak load and regional similarity of load profiles following disturbances based on data minig. **International Journal of Electrical Power & Energy Systems**, Oxford, v. 28, n.3, p. 177-185, 2006. DOI: <https://doi.org/10.1016/j.ijepes.2005.11.014>.

LIU, H.; WANG, Y.; WEI, C.; LI, J.; LIN, Y. Two-stage short-term load forecasting for power transformers under different substation operating conditions. **IEEE Access**, New York, v. 7, p. 161424-161436, 2019. DOI: <https://doi.org/10.1109/ACCESS.2019.2951422>.

LOMAS-BARRIE, V.; PENA-CABRERA, M.; LOPEZ-JUAREZ, I.; NAVARRO-GONZALES, J. L. Fuzzy ARTMAP-Based Fast Object Recognition for Robots Using FPGA, MDPI. **Electronics**, v. 10, n. 3, p. 361, 2021. DOI: <https://doi.org/10.3390/electronics10030361>.

LOPES, M. L. M.; MINUSSI, C. R.; LOTUFO, A. D. P. Electric load forecasting using a fuzzy ART&ARTMAP neural network. **Applied Soft Computing**, Amsterdam, v. 5, p. 235-244, 2005. DOI: <http://dx.doi.org/10.1016/j.asoc.2004.07.003>.

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

MARCHIORI, S. C.; DA SILVEIRA, M. C.; LOTUFO, A. D. P.; MINUSSI, C. R.; LOPES, M. L. M. Neural network based on adaptive resonance theory with continuous training for multi-configuration transiente stability analysis of electric power systems. **Applied Soft Computing**, Amsterdam, v. 11, n. 1, p. 706-715, 2011, DOI: <https://doi.org/10.1016/j.asoc.2009.12.032>.

MARCHIORI, S. C. **Desenvolvimento de um sistema para análise da estabilidade transitória de sistema de energia elétrica via redes neurais**. 2006. 110 f. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2006.

MATIAS A. L. S.; ROCHA NETO, A. R.; MATTOS, C. L. C.; GOMES, J. P. P. A novel fuzzy ARTMAP with área of influence. **Neurocomputing**, Amsterdam, v. 432, p. 80-90, 2021. DOI: <https://doi.org/10.1016/j.neucom.2020.11.053>.

MCDONALD, J. D. **Electric power substations engineering**. 3th. Londo: CRC, 2012.

MENDES FILHOS, E. F.; CARVALHO, A. C. P. L. Evolutionary design of MLP neural network architectures. In: SIMPÓSIO BRASILEIRO DE REDES NEURAIIS -SBRN, 4., 1997, Campos do Jordão. **Anais [...]** São Paulo: [s. n.], 1997. p. 58-65.

MEYER, Y. Principe d'incertitude, bases hilbertiennes *et* algebres d'operateurs. **Séminaire Bourbaki**, Marseille, v. 662, p. 1985-1986, 1985.

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.

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

NASSAR, S. M., A Estatística como apoio à inteligência artificial: sistemas especialistas probabilísticos. In: **Estatística e Informática: um processo interativo entre duas ciências**. Trabalho apresentado no Concurso para Professor Titular, Departamento de Informática e de Estatística, Centro Tecnológico, Universidade Federal de Santa Catarina, 1998. 128p.

NOSE-FILHO, K.; LOTUFO, A. D. P.; MINUSSI, C. R. Short term Multinodal Load Forecasting Using a Modified General Regression Neural Network. **IEEE Transaction on Power Delivery**, New York, v. 26, n. 4, p. 2862-2869. 2011a. DOI: <https://doi.org/10.1109/TPWRD.2011.2166566>.

O'DONOVAN, T. M. **Short term forecasting**: an introduction to the Box-Jenkins approach. New York: John Wiley & Sons, 1983. 256p.

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. DOI: <https://doi.org/10.1109/59.76685>.

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, Nov. 1974. <https://doi.org/10.1109/CDC.1974.270506>.

QAHTANI, F. H. A.; CRONES, F. Multivariate k-nearest neighbour regression for time series data_A novel algorithm for forecasting UK electricity demand," in *Proc. IJCNN*, Dallas, TX, USA, Aug. 2013. p. 1-8.

QIN, J.; ZHANG, Y.; FAN, S.; HU, X.; HUANG, Y.; LU, Z.; LIU, Y. Multi-task short-term reactive and active load forecasting method based on attention-LSTM model. **International Journal of Electrical Power & Energy Systems**, London, v. 135, P. 107517, 2022. DOI: <https://doi.org/10.1016/j.ijepes.2021.107517>.

SANTOS, J. A. A.; CHAUCOSKI, Y. Previsão do Consumo de Energia Elétrica na Região Sudeste: Um Estudo de Caso Usando SARIMA e LSTM. **Revista Cereus**, [s. l.], v. 12, n.4, 2020. DOI: 10.18605/2175-7275/cereus.v12n4p93-104.

SHAFIUL HASAN, R.; NAHID-AL-MASOOD, S. R. D.; EKLAS, H. A Short-Term Load Forecasting Method Using Integrated CNN and LSTM Network. **IEEE Access**, New York, 2021. DOI: <https://doi.org/10.1109/ACCESS.2021.3060654>.

SHAHRAFI, J., HADAVANDI, E., ASADI, S., Developing a hybrid intelligent model for forecasting problems: Case study tourism demand time series. **Knowledge-Based Systems**, Amsterdam, v. 43, n. 13, p. 112-122, 2013. DOI: <https://doi.org/10.1016/j.knosys.2013.01.014>.

SIDERATOS, G.; IKONOMOPOULOS, A.; HATZIARGYRIO, N. A novel fuzzy-based ensemble model for load forecasting using hybrid deep neural networks. **Electric Power Systems Research**, v. 178, p. 106025, 2019.

SINGH, P., DWIVEDI, P., Integration of new evolutionary approach with artificial neural network for solving short term load forecast problem. **Applied Energy**, Oxford, v. 217, 2018, p. 537-549, 2018. DOI: <https://doi.org/10.1016/j.apenergy.2018.02.131>.

SMYL, S. A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. **International Journal of Forecasting**, Amsterdam, v. 36, p. 75–85, 2020. DOI: <https://doi.org/10.1016/j.ijforecast.2019.03.017>.

SRINIVASAN, DIPITI.; TAN, SWEE SIEN; CHANG, CHE-SAU SAU; CHAN, ENG KIAT. Practical implementation of a hybrid fuzzy neural network for one-day-ahead load forecasting. **IEEE Proceedings Generation, Transmission and Distribution**, New York, v. 145, n. 6, p. 687- 692, 1998.

SUN, Y.; LI, S.; WANG, Y.; WANG, X. Fault diagnosis of rolling bearing based on empirical mode decomposition and improved manhattan distance in symmetrizer dor pattern image. **Mechanical Systems and Signal Processing**, London, v. 159, p. 107817 2021. DOI: <https://doi.org/10.1016/j.ymssp.2021.107817>.

SUN, X.; LUH, P.B.; CHEUNG, K. W.; GUAN, W.; MICHEL, L. D.; VENKATA, S. S.; MILLER, M. T. An Efficient Approach to Short-Term Load Forecasting at the Distribution Level. **IEEE Transactions on Power Systems**, New York, v. 31, n. 4, p. 2526-2537, 2016. DOI: <https://doi.org/10.1109/TPWRS.2015.2489679>.

TAKIYAR, S.; UPADHYAY, K. G.; SINGH, V. Fuzzy ARTMAP and GARCH-based hybrid model aided with wavelet transform for short-term electricity loas forecasting. **SCIPEDIA – Collection of Energy Science & Engineerig**, 2017. DOI: <https://doi.org/10.1002/ese3.105>.

TAYLOR, G.W.; HINTON, G.E.; ROWEIS, S.T. Two distributed-state models for generating high-dimensional time series. **J Mach Learn Res**, [s. l.], v. 12, p. 1025–1068, 2011.

VUSKOVIC, M.; DU, S. **Classification of Prehensile EMG Patterns With Simplified Fuzzy ARTMAP Networks**. Honolulu: IEEE Xplore, 2002. DOI: <https://doi.org/10.1109/IJCNN.2002.1007543>.

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

WIDROW, B., LEHR, M. A. 30 years of adaptive neural networks: perceptron, madaline and backpropagation. **Proceedings of the IEEE**, New York, v. 78, n. 9, p. 1415-1442, 1990.

WILLIAMSON J. R., Gaussian ARTMAP: A Neural Network for Fast Incremental Learning of Noisy Multidimensional Maps. **Neural Networks**, v. 9, n. 5, p. 881-897, 1996. DOI: [https://doi.org/10.1016/0893-6080\(95\)00115-8](https://doi.org/10.1016/0893-6080(95)00115-8).

XU, H.; VUSKOVIC, M. **Mahalanobis Distance-Based ARTMAP Network**. Budapest: IEEE Xplore, 2004. DOI: <https://ieeexplore.ieee.org/document/1380994>.

YANG, Y.; CHEN, Y.; WANG, Y.; CAIHONG, L.; LI, L. Modelling a combined method based on ANFIS and neural network improved by DE algorithm: a case study for short-term electricity demand forecasting. **Applied Soft Computing**, v. 49, p. 663-675, 2016. DOI: <https://doi.org/10.1016/j.asoc.2016.07.053>.

ZADEH, L., A. Fuzzy sets. **Information and Control**, Maryland Heights, v. 8, n. 3, p. 338-353, 1965.

ZADEH, L. A. Fuzzy logic. **Computer**, New York, v. 21, n. 4, p. 83-93, 1988.

ZHANG, R.; XU, Y.; DONG, Z.; KONG, W.; WONG, K. P. A composite k-nearest neighbor model for day-ahead load forecasting with limited temperature forecasts. *In: PESGM, 2016, Boston. Proceedings [...]* Boston: [s. n], 2016, p. 1-5.

ZHANG, C.; LI, J.; ZHAO, Y.; LI, T.; CHEN, Q.; ZHANG, X. A hybrid deep learning-based method for short-term building energy load prediction combined with an interpretation process. Elsevier, **Energy & Building**, Greenfield, v. 255, 2020. DOI: https://doi.org/10.1016/j.enbuild.2020.1103010378-7788/_ 2020.

ZHANG, X.; LI, R.; HOU, W.; SHI, J. **Research on Manhattan Distance based trust Management in Vehicular Ad Hoc Network**. London: Wiley, 2021. DOI: <https://doi.org/10.1155/2021/9967829>.

APÊNDICE A – Código da Função Escolha da Categoria

A equação da função escolha da categoria ativa do neurônio vencedor é realizada na Camada de Reconhecimento (F_2), que classificará os padrões de treinamento aprendidas pela rede neural artificial. A função de Escolha (T_j) da rede neural ARTMAP Euclidiana e da ARTMAPManhattan na forma de código de programação com a linguagem do Matlab está expressa no Quadro 1.

Quadro 9 – Código da Escolha da Categoria.

Função Escolha Categoria	
ARTMap Euclidiana	$Tb(i) = (Ib(j, :) - wb(i, :)) * (Ib(j, :) - wb(i, :))';$ $Ta(i) = (Ia(j, :) - wa(i, :)) * (Ia(j, :) - wa(i, :))';$
ARTMap Manhattan	$Tb(i) = abs(Ib(j, :) - wb(i, :)) * abs(Ib(j, :) - wb(i, :))';$ $Ta(i) = abs(Ia(j, :) - wa(i, :)) * abs(Ia(j, :) - wa(i, :))';$

Fonte: Própria Autora.

ANEXO A – Rede Neural ARTMAP Euclidiana

O modelo da rede neural ARTMAP é adequado para a resolução de problemas de classificações, análises e previsões, por causa da proeminência que ocorre no sistema da família ART, que é a característica da estabilidade e plasticidade, as quais oferecem à rede neural uma aprendizagem estável, múltipla generalização e convergência rápida (MARCHIORI, 2006).

As redes ART's, apresentam algumas dificuldades, como na sensibilidade dos parâmetros da rede e a precisão das análises. Por meio de novas técnicas de treinamento e na arquitetura das redes neurais ART's, tem sido solucionado ou amenizado os problemas de imprecisão decorrente do mecanismo da escolha de categoria e do teste de vigilância, que necessita de aperfeiçoamento (MARCHIORI, 2006; WILLIAMSON, 1996).

A rede ARTMAP Euclidiana apresenta algumas diferenças se relacionarmos com a rede ARTMAP *Fuzzy*. A primeira oposição está na entrada de dados dos vetores, em que não é necessário a normalização e a codificação complementar dos vetores, reduzindo o custo computacional (VUSKOVIC, 2002), em contraste com outras arquiteturas da família ART. Não contém o parâmetro de escolha (α) contido na camada F_2 para escolha dos neurônios, neste caso, a rede ARTMAP Euclidiana utiliza uma norma baseada na distância euclidiana para a realização da função escolha da categoria (GOMES, 2017).

A função decategoria apresentada na rede neural ARTMAP Euclidiana sobrevém da equação da distância Euclidiana entre dois pontos $x = [x_1 x_2 \dots x_p]$ e $y = [y_1 y_2 \dots y_p]$ em um espaço p -dimensional, é definida como (URL, 2005):

$$d_E(x, y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_p - y_p)^2} = \sqrt{(x - y)(x - y)^T} \quad (40)$$

$$d_E(x, 0) = \|x\|_2 = \sqrt{x_1^2 + x_2^2 + \dots + x_p^2} = \sqrt{x x^T} \quad (41)$$

O operador AND ($\wedge$), definido pela teoria dos conjuntos *Fuzzy*, utilizados nas equações da função da categoria e no teste de vigilância utilizado nas redes neurais


tradicionais ART e ARTMAP não são mais utilizados, logo, os cálculos são baseados somente na distância euclidiana (GOMES, 2017).

Na fase do treinamento, é acrescentado (incorporado) na rede um neurônio “vazio”, representando uma categoria de reconhecimento sem a presença de nenhum padrão de entrada (MARCHIORI, 2006), podendo diminuir o número de candidato a vencedor, portanto, diminuindo o número de neurônios por competição.

Ao invés de usarmos a maximização para determinarmos a função da escolha da categoria, empregado nas redes ART e ARTMAP, passa-se a utilizar a minimização para a escolha das categorias (GOMES, 2017).

Geometricamente, utilizam os hiperretângulos na representação do cálculo da função de categoria nas redes neurais ART e ARTMAP, mas nem sempre esta geometria é necessariamente a melhor representante para agrupar os dados de entrada, considerando, um sistema de dados bi-dimensional que implicando uma representação de categoria elipsoidal, o uso dos retângulos seria ineficiente para descrever os padrões, então, neste caso os cantos do retângulo obtêm a presença de padrões a mais mostrado na Figura 35(GOMES, 2017).


Figura 35- Representação Geométrica da Categoria Elipsoidal Comparada com a Categoria do Hiperretângulo.



Fonte: Marchiori(2006).

A geometria dos hiper-retângulos criada pela lógica *Fuzzy* agora passa a ser das hiper-esferas centradas no centro das classes. Na Figura 36 a linha tracejada é a categoria nova depois da aprendizagem (treinamento). Esta categoria contém regiões que não estão na direção (parte sombreada na figura) da categoria antiga aos vetores padrão de entrada, mostra que o volume destas regiões crescem com a dimensão do espaço de entrada se comparar com a ARTMAP_{Fuzzy} em $\mathbb{R}^2$ e $\mathbb{R}^3$ (GOMES, 2017).

Figura 36- Comparação entre as Geometrias das Categorias em Hiper-retângulos e Hiper-esferas.



Fonte: Amorim(2006).

O modelo apresentado pelo algoritmo da rede neural ARTMAP Euclidiana a ser executado para a realização do processamento da rede neural está dividido em três etapas, em seus respectivos passos (GOMES, 2017):

1ª Etapa - Início: Definição do vetor padrão de entrada, pesos e parâmetros.

Passo 1: Leitura dos Padrões de Entrada e Saída:

O vetor ART_a representa um padrão de entrada e o vetor ART_b a saída desejada correspondente ao vetor de entrada ART_a . Não é necessário o processo de normalização e a complementação dos vetores de entrada, por esse motivo, o tamanho dos vetores ficam pela metade se comparada com a tradicional ARTMAPFuzzy.

- Vetor de entrada: $I_j^a = [a_1 \ a_2 \ ... \ a_M]$
- Vetor de saída: $I_k^b = [b_1 \ b_2 \ ... \ b_M]$;

Sendo:

M : número de dimensão do vetor.

Passo 2: Construção das matrizes pesos:

Os Pesos w_j^a e w_k^b são iniciados com valor igual a 0, indicando a presença de um único *cluster* (categoria) ativa. O peso w_{jk}^{ab} inicia com o valor igual a 1, indicando que não existe nenhuma categoria ativa.

Passo 3: Leitura dos Parâmetros:

Os parâmetros essenciais para o desenvolvimento da rede neural ARTMAPEuclidiana são:

- β : taxa de treinamento $[0, 1]$;
- ρ_a : parâmetro de vigilância do módulo ART_a $[0, 1]$;
- ρ_b : parâmetro de vigilância do módulo ART_b $[0, 1]$;
- ρ_{ab} : parâmetro de vigilância do módulo ART_{ab} $[0, 1]$;
- ε : decremento do parâmetro ρ_a .

2ª Etapa - Processo de Treinamento dos dados do vetor padrão de entrada nos módulos: ART_b Euclidiana e ART_a Euclidiana.

Passo 4:

Cálculo das funções T_k^b e T_j^a com o uso da distância Euclidiana.

$$T_k^b = (I_k^b - w_k^b)(I_k^b - w_k^b)^T \quad (42)$$

$$T_j^a = (I_j^a - w_j^a)(I_j^a - w_j^a)^T \quad (43)$$

Passo 5:

O índice K indica a categoria escolhida.

$$T_K^b = \min\{T_k: k = 1, \dots, N\} \quad (44)$$

Passo 6:

O critério de vigilância do módulo ART_b é determinado através da função.

$$\frac{T_K^b}{\max(I_K^b I_K^{b^T}, w_K^b w_K^{b^T})} < \rho_b \quad (45)$$

Passo 7:

Se o critério de vigilância for satisfeito, houve ressonância e passa-se para próximo passo no qual se atualiza o vetor peso w_K^b .

$$w_K^b = \beta(I_K^b) + (1 - \beta)w_K^b \quad (46)$$

Passo 8:

Cálculo do vetor atividade para o número de categorias criadas

$$y_K^b = [y_1^b \ y_2^b \ \dots \ y_N^b]$$

Para:

$$y = \begin{cases} y_k^b = 0, & \text{se } k \neq K \\ y_k^b = 1, & \text{se } k = K \end{cases} \quad (47)$$

Passo 9:

Se o critério de vigilância não for satisfeito, então não houve ressonância e faz-se $T_K^b = 0$ e ocorre o *reset*.

O módulo ART_a possui a mesma estrutura e característica do módulo ART_b Euclidiana usada anteriormente, porém a atualização de w_j^a e vetor atividade y_j^a , será realizado somente depois do módulo *Inter-ART*, logo após o teste de vigilância. Na ultima etapa deste módulo verifica-se se há o “casamento” da entrada de ART_a com a saída de ART_b . (GOMES, 2017).

3ª Etapa - É na finalização deste módulo que se verifica se houve “casamento” entres os Módulo ART_a Euclidiana e Módulo ART_b Euclidiana.

Passo 10:

O critério de vigilância no módulo *Inter-ART* é verificado por meio da equação (48):

$$|y_j^b \wedge w_j^{ab}| > \rho_{ab} \quad (48)$$

Passo 11:

Vetor atividade do Módulo ART_a Euclidiana.

$$y_j^a = [y_1^a \ y_2^a \ \dots \ y_N^a]$$

Para:

$$y_j^a = \begin{cases} y_j^a = 0, & \text{se } j \neq J \\ y_j^a = 1, & \text{se } j = J \end{cases} \quad (49)$$

Passo 12:

Atualização do vetor de pesos w_j^a .

$$w_j^a = \beta(I_j^a) + (1 - \beta)w_j^a \quad (50)$$

Passo 13:

Atualização do vetor de pesos W_{JK}^{ab} .

$$W_{JK}^{ab} = [y_1^{ab} \ y_2^{ab} \ \dots \ y_N^{ab}]$$

Para:

$$y_{jk}^{ab} = \begin{cases} 0, & \text{se } j = J; k \neq K \\ 1, & \text{se } j = J; k = K \end{cases} \quad (51)$$

Passo 14:

Se não ocorre ressonância no módulo Inter-ART é acrescentado um incremento no parâmetro de vigilância.

$$\rho_a = \frac{T_j^a}{\max(I_j^a I_j^{aT}, w_j^a w_j^{aT})} - \varepsilon \quad (52)$$


Passo 15:

E volta para a escolha do índice J indicando a categoria escolhida.

$$T_j^a = \min\{T_j: j = 1, \dots, N\}$$

Este procedimento termina quando a categoria escolhida (vencedora) selecionada atenda (satisfaça) o teste de vigilância. O fluxograma na Figura 37 representa as etapas realizadas pela rede ARTMAP Euclidiana.

Figura 37 – Fluxograma da Rede ARTMAP Euclidiana.



Fonte: própria autora.

ANEXOB– Teoria da Ressonância Adaptativa

Quando se treina uma rede espera-se que ela proporcione (conceda) respostas eficientes para qualquer padrão de entrada, conforme seu conhecimento, adquirido posteriormente. Portanto seu conhecimento pode sofrer variações com o passar do tempo e, para ajustar novos padrões de entrada indeterminados necessita-se que o algoritmo seja plástico. Uma solução para este problema seria retreinar a rede, entretanto, as informações adquiridas poderão se perder. E, para que se conserve este novo conhecimento, a rede também necessita ser estável. Este problema é conhecido como o dilema da estabilidade e plasticidade (CARPENTER & GROSSBERG, 1991, GOMES,2017).

Então, é preciso uma rede incremental que não necessite de um novo começo para cada vez que se apresentem novos padrões de entrada e que conserve suas informações. Em 1976, Grossberg questiona:


- Como pode uma rede conservar seu conhecimento adquirido e ao mesmo tempo ser flexível para armazenar seu novo conhecimento?
- Como pode um sistema ser treinado adaptado (plástico) e permanecer estável a informações imprecisas?
- Como pode um sistema ser plástico e estável ou vice-versa? Ele próprio responde estas questões com a Teoria da Ressonância Adaptativa (ART). Christoph Von der Malsburg (1973), foi um dos pioneiros a apresentar uma rede neural artificial com propriedades de auto-organização para modelagem de córtex visual das vertebras superiores (AMORIM, 2006) e influenciou os trabalhos de Teuvo Kohonen e Steven Grossberg. Kohonen desenvolveu a rede SOM (*Self-Organizing Maps*) que faz o mapeamento com características auto-organizável. Grossberg desenvolveu GN (*Grossberg Network*) a primeira rede com arquitetura baseada na teoria da ressonância adaptativa, esta rede apresenta duas camadas, a primeira faz a implementação dos dados de entrada e a segunda camada, no qual é competitiva com conectividade de realimentação não-linear, executa a seleção dos padrões de saída e os armazena na memória (GOMES,2017).

A importância desta rede está baseada na resolução do dilema da plasticidade e estabilidade, realizado pelo teste de vigilância para a administração de inclusão de novas entradas em cada grupo. A plasticidade é a capacidade que a rede tem de aprender um novo

padrão, em qualquer tempo de sua operação, sem perder o aprendizado adquirido anteriormente. A estabilidade está vinculada com a garantia de agrupamento de todos os elementos nas categorias criadas pelo sistema, tendo em vista que os pesos da rede possuem características somente de decrescimento, ou seja, conforme os ajustes (as adaptações) dos pesos são realizados, os novos valores tendem sempre a diminuir até a estabilização. Na atividade de reconhecimento de padrões de entrada, quando algum dado não assemelha a nenhum dos grupos já existentes, um novo grupo é escolhido para a referida entrada. Esta habilidade em algumas redes neurais podem afetar a estabilidade do sistema, ou seja, se houver uma nova aprendizagem, podem os padrões anteriormente já treinados serem prejudicados, podendo sofrer com a perda da capacidade de reconhecer os padrões antigos, nas redes ART este problema como escrito no começo do parágrafo, é resolvido com o teste de vigilância que administra as novas entradas em cada grupo (GOMES,2017).

São citados diversos modelos de rede oriundos da família ART, na Figura38.

Figura 38- Surgimento das Principais Redes da Família ART.




Fonte: própria autora

- **Rede Neural ART1:** possui treinamento não supervisionado e tem a capacidade de reconhecer padrões de entrada binários aleatoriamente (CARPENTER& GROSSBERG, 1987).
- **Rede Neural ART2:** treinamento não supervisionado e possui a capacidade de reconhecer padrões de entrada binários e analógicos (CARPENTER& GROSSBERG, 1987).
- **Rede Neural ART Fuzzy:** treinamento não supervisionado possuindo uma arquitetura de cálculos baseado na lógica *fuzzy* (CARPENTER *et al.*,1991b).

- **Rede Neural ARTMAP:** treinamento supervisionado, composta por dois módulos ART's, interconectados através do módulo inter-ART (CARPENTER *et al.*,1991a).
- **Rede Neural ARTMAP Fuzzy:** treinamento supervisionado, semelhantemente a ARTMAP difererindo somente nos cálculos, em que são baseados na lógica *fuzzy* (CARPENTER *et al.*,1992).

Os modelos neurais ART têm adicionado uma série de novos princípios de teoria original, fazendo com que as redes possam ser aplicadas na aprendizagem de categorias, reconhecimento de padrões e predição (CARPENTER, 1997; CARPENTER & GROSSBERG, 1987b; CARPENTER & GROSSBERG, 1990). O primeiro modelo de família ART1 definido por Carpenter & Grossberg(1987a) está ilustrado na Figura 39.

Figura 39- Modelo da ART1.



Fonte: Araken (Adaptado).

A arquitetura de modelo ART1 é composta por três camadas:

- A primeira camada (F_0) armazena o vetor de entrada transferindo-o para próxima camada (F_1), juntamente com seu complemento.
- A camada intermediária (F_1), serve de camada de comparação e faz o processamento dos dados recebido da camada anterior.

- A última camada (F_2), denominada camada de saída faz o reconhecimento agrupando os padrões treinados em *clusters* (categorias, grupos).

As camadas (F_1) para (F_2) são conectadas através de conexões não-recorrentes (diretas) ou *feedforward* os pesos associados com as conexões de baixo para cima ou *bottom-up*.

As camadas de (F_2) para (F_1) são conectadas através das conexões recorrentes (indireta) ou *feedback*, e os pesos de cima para baixo ou *top-down*.


Entre as camadas (F_1) e (F_2) está o que chamamos de memória a longo prazo (*long-term memory- LTM*) (GOPAL *et al.*, 1999; KEYVAN *et al.*, 1999).

A arquitetura da rede ART é provida de dois subsistemas:

- Subsistema de Atenção: composto por duas camadas de neurônios, a camada (F_1) tem a função de processar os dados de entradas e a camada (F_2), classifica os padrões de treinamento em categorias de reconhecimento em cada camada de vários neurônios.
- Subsistema de Orientação: é constituído por um controlador que determina se um padrão de entrada pode ser aceito (incluído) em umas das categorias existentes, este controlador é o Parâmetro de Vigilância, é aqui, que ocorre o que se chama de ressonância ou o reset determinando a classificação das categorias.

A Figura 40 mostra os subsistemas da arquitetura de uma rede ART.

Figura 40- Subsistema de Atenção e Orientação.



Fonte: Lopes (2005).

A geometria da Rede Neural ART


As categorias desenvolvidas pela rede neural ART são demonstradas em hiper-retângulos, em que são definidos os valores entre Min. (Mínimo) e Max. (Máximo). Na Figura 41, tem-se a representação geométrica dos vetores $u = [u_1 \ u_2]$ e $v = [v_1 \ v_2]$ com os operadores lógicos AND e OR da lógica *fuzzy* (CARPENTER& GROSSBERG, 1992).

$$(u \wedge v)_1 = \min(u_1, v_1) (u \wedge v)_2 = \min(u_2, v_2) \quad (53)$$

$$(u \vee v)_1 = \max(u_1, v_1) (u \vee v)_2 = \max(u_2, v_2) \quad (54)$$

As posições u e v são originadas do vetor peso, $w_j = [u_j \ v_j]$, na forma de codificação de complemento, sendo $v_j = u_j^c$.

Figura 41- Representação Geométrica da Rede ART.



Fonte: Lopes(2005).

Existem parâmetros que controlam a rede neural ART, portanto, são de grande importância para o desenvolvimento da aprendizagem. Os parâmetros em destaque são:

- Parâmetro de escolha (aprendizagem) ($\alpha > 0$): controla a sequência de busca entre os neurônios da camada F_2 . Supondo que um ponto (entrada de dados) pertença a mais de um hiper-retângulo, o parâmetro de escolha irá conferir que o menor dos hiper-retângulos seja o escolhido entre os demais (GOPAL *et al.*, 1999; WEENINK, 1997).

- Parâmetro de treinamento ($\beta \in [0\ 1]$): se β tem um valor próximo de zero, demonstra um treinamento lento, caso contrário, ou seja, β com valor próximo de um, seu treinamento será rápido.
- Parâmetro de vigilância ($\rho \in [0\ 1]$): verifica se os padrões de entrada e os pesos tenham combinação para obter a ressonância. Se ρ possui um valor inferior, próximo de zero, a rede permite que os padrões poucos idênticos sejam agrupados na mesma categoria, gerando pequenos números de classes. Caso ρ for atribuído um valor grande, próximo de um, pequenas variações nos padrões de entrada levarão à criação de novas classes (MARCHIORI, 2006).


Rede Neural ART *Fuzzy*

Esta rede possui uma arquitetura de cálculos de operadores que intervêm da teoria dos conjuntos *fuzzy* (ZADEH, 1965), em sistemas ART. O diferencial entre as redes ART E ART *Fuzzy* está no operador de interseção ($\cap$), utilizado na rede ART, enquanto que na rede ART *Fuzzy* é empregado o operador *AND* ($\wedge$), isto facilita no processo dos dados analógicos e binários (LOPES, 2005).

A arquitetura está representada na camada de pré-processamento de neurônios, F_0 , que transforma o vetor de entrada atual, uma camada F_1 , que adquire tanto entradas de F_0 , quanto as entradas de F_2 , e a camada F_2 possui um número suficiente de nós para acomodar os padrões de entrada em categorias e realizar o treinamento (LOPES, 2005; MARCHIORI, 2006).

Através da Figura 42, pode-se ter uma melhor percepção do funcionamento da rede neural ART *Fuzzy*.

Figura 42- Rede Neural ART Fuzzy.



Fonte: Amorim (2006).

O algoritmo da rede neural ART Fuzzy pode ser resumido nos seguintes passos:

- **Passo 1:** Inicialização de pesos e parâmetros da rede.

Ao iniciar, os pesos são todos adotados com um mesmo valor igual a 1, indicando que a categoria não está ativa, $w_{ij} = 1$, o parâmetro de vigilância será escolhido entre 0 e 1, $\rho \in [0, 1]$, o parâmetro de escolha será maior que zero, $\alpha > 0$, e a taxa de treinamento entre 0 e 1, $\beta \in [0, 1]$.

- **Passo 2:** Codificação Complementar do vetor de entrada.

Um novo padrão de entrada $a = [a_1 a_2 \dots a_N]$ de N elementos em que cada elemento a_i é um número real no intervalo $[0, 1]$ passa por uma codificação complementar para preservar a amplitude da informação que produzirá um vetor de entrada I de $2N$ elementos, tal como:

$$I = [a \ a^c] = [a_1 a_2 \dots a_N \ a_1^c a_2^c \dots a_N^c]$$

Note que:

$$|I| = \sum_{i=1}^N a_i + \sum_{i=1}^N a_i^c = N, \text{ todos os vetores terão o mesmo comprimento de } N.$$

- **Passo 3:** Escolha da Categoria

A ativação T_j é calculada para cada neurônio j de F_2 , conforme a função escolha dada pela equação (55):

$$T_j = \frac{|I \wedge w_j|}{\alpha + |w_j|} \quad (55)$$

Sendo:

$\wedge$ = operador *fuzzy* AND, definido por:

$$(I \wedge w)_i = \min(I_i, w_i) \quad (56)$$

Quando no máximo um neurônio se torna ativo, então dizemos que ele teve “a escolha da categoria”, e passa a ser indexada por J (J , maiúsculo ou Jotão), em que:

$$T_j = \max\{T_j : j = 1, \dots, M\} \quad (57)$$

Caso exista mais de um T_j máximo, a categoria j com menor índice é escolhida (SANTOS JÚNIOR, 2013).

- **Passo 4:** Ressonância - Teste de Vigilância

A ressonância ocorre se a função da escolha da categoria ganhadora J satisfaz o teste de vigilância:

$$\frac{|I \wedge w_J|}{I} \geq \rho \quad (58)$$

Se a equação (58) não é satisfeita, então o valor da função de escolha T_j é fixo em 0 (zero)(reset), para evitar que uma seleção persista na mesma categoria durante o processo de busca. Então a busca se encerra quando a categoria J escolhida atenda a equação (58) (LOPES, 2005).

- **Passo 5:** Aprendizagem – Atualização de vetor protótipo

O vetor peso w_j é atualizado através da equação (59) (CARPENTER& GROSSBERG, 1991c):

$$w_j^{(novo)} = \beta(I \wedge w_j^{(velho)}) + (1 - \beta)w_j^{(velho)} \quad (59)$$

Quando $\beta = 1$, tem-se o treinamento rápido. Se o treinamento for rápido, isto permitirá uma atualização com maior rapidez, conforme a equação (60):

$$w_j^{(novo)} = I \wedge w_j^{(velho)} \quad (60)$$

Rede Neural ARTMAP

A rede neural ARTMAP (CARPENTER, et. al., 1991^a), foi programada a fim de se obter o treinamento supervisionado e auto-organizável sem perder a estabilidade do processo da aprendizagem, diferentemente da rede ART, proposta para classificação não supervisionada de padrões.

A estrutura básica da rede neural ARTMAP é composta de dois módulos ART, sendo um disponibilizado para processamento do vetor de entrada. O segundo módulo é destinado para o pré-processamento dos dados de saída.

O terceiro módulo, Inter-ART ou *Match Tracking*, que fará o mapeamento para associar (combinação) os neurônios, tanto do módulo ART_a , quanto ao módulo ART_b . Toda vez que a rede faz um prognóstico, por meio da conexão associativa instruída, o parâmetro de vigilância (ρ_a), pertencente ao módulo ART_a , é elevado a uma quantidade mínima para corrigir o erro no módulo ART_b .

O módulo ART_a buscará, então, uma nova categoria para a entrada atual até que se ache um prognóstico correto, e a sua correspondente conexão associativa à categoria no módulo ART_b (LIM; HARRISON, 1997). O módulo ART_a classifica os padrões de entrada apresentados na primeira camada, F_0^a , e o módulo ART_b , com os parâmetros de vigilância (ρ_b), desenvolve categoria referente aos padrões de saída desejado apresentado na primeira camada F_0^b .


O “módulo” ou “campo” *Inter-ART*, F^{ab} , recebe entradas de ambos os módulos ART_a e ART_b , se as entradas combinam, então, é confirmado o prognóstico selecionado pela categoria, conforme o treinamento, a rede modificará os protótipos das categorias escolhidas em ART_a e ART_b .

Caso as duas entradas não combinam, um sinal de *reset* será feito e o processo de *match tracking* inicializará de maneira que o grau do parâmetro de vigilância no ART_a terá um

incremento mínimo para que não ocorra a combinação para aquela entrada atual de ART_a na camada F_1^a . Ativará uma nova busca, escolhendo uma nova categoria no ART_a , cujo prognóstico será combinado novamente com a categoria atual do ART_b .

A adaptação/ajuste dos pesos, realizada no módulo *Inter-ART* entre uma categoria ativa J do ART_a e uma categoria ativa K do ART_b é feita de maneira que, a conexão correspondente as categorias ativas dos módulos ART_a e ART_b , ou seja, a conexão entre $F_2^a \rightarrow F^{ab}$, terá valor 1(um) e as demais conexões referentes ao mesmo nó do ART_a terá valor igual a 0(zero) (LOPES, 2005; KARTALOPOULOS, 1996; LIM; HARRISON, 1997). A Figura 43 ilustra a estrutura de uma rede ARTMAP.

Figura 43- Rede Neural ARTMAP.




Fonte: Amorim(2006).

Rede Neural ARTMAPFuzzy

Basicamente, o modelo da rede neural ARTMAPFuzzy (CARPENTER, 1992), tem a mesma estrutura da rede ARTMAP (CARPENTER, 1991), apresentada com entrada e saída desejada nos módulos ART_aFuzzy e ART_bFuzzy , sendo a saída desses módulos associados ao módulo de mapeamento, *Inter-ART*, o detalhe está na utilização dos operadores, com o uso da teoria do conjunto *fuzzy*.

Na Figura 44 o fluxograma mostra como é o funcionamento da rede ARTMAPFuzzy, com todas suas funções e operações.

Figura 44- Fluxograma da Rede Neural ARTMAP Fuzzy.



Fonte: Lopes (2005) Adaptada.